

DAS Departamento de Automação e Sistemas
CTC **Centro Tecnológico**
UFSC Universidade Federal de Santa Catarina

Implementação e avaliação de uma ferramenta de acompanhamento de controle preditivo para processos da indústria do petróleo

*Relatório submetido à Universidade Federal de Santa Catarina
como requisito para a aprovação da disciplina:*

DAS 5511: Projeto de Fim de Curso

Carolina Maia Vettorazzo

Florianópolis, agosto de 2014

Implementação e avaliação de uma ferramenta de acompanhamento de controle preditivo para processos da indústria do petróleo

Carolina Maia Vettorazzo

Esta monografia foi julgada no contexto da disciplina

DAS 5511: Projeto de Fim de Curso

e aprovada na sua forma final pelo

Curso de Engenharia de Controle e Automação

Prof. Júlio Normey-Rico

Banca Examinadora:

Mario César M. Massa de Campos
Orientador Empresa

Júlio Normey-Rico
Orientador do Curso

Prof. Ricardo José Rabelo
Responsável pela disciplina

Prof. xxxxxxxx, Avaliador

aluno1, Debatedor

aluno2, Debatedor

Agradecimentos

Antes de tudo, agradeço à minha família que me apoiou e me acompanhou durante toda a graduação. Obrigado por terem sido mais fortes do que eu e por nunca terem duvidado de mim, mesmo nos momentos mais difíceis.

Agradeço ao professor Julio Normey-Rico e ao engenheiro Mario Campos pela orientação e pela oportunidade de desenvolver este trabalho.

Também agradeço aos membros do projeto na UFSC, que me apoiaram a distância e muito me ensinaram sobre o tema, e a todos que conheci no Cenpes pelos conhecimentos passados a mim, pela ajuda com o meu projeto e pelos momentos descontraídos, que tornaram meu estágio tão divertido.

Aproveito também para agradecer aos meus amigos, não só aos que estiveram ao meu lado durante minha jornada acadêmica, mas também aos que estiveram longe e mesmo assim não esqueceram de mim.

Por fim, dedico este trabalho a todos aqueles que conheci através dos projetos de pesquisa dos quais participei, da empresa júnior Autojun, do centro acadêmico CAECA e do programa CInências sem Fronteiras, e que contribuíram de alguma forma para o meu crescimento pessoal e para minha formação profissional.

Resumo

O controle preditivo baseado em modelo (CPBM) é uma das técnicas de controle moderno que provavelmente teve mais êxito nas aplicações na indústria. Porém, uma das dificuldades encontradas na aplicação de CPBM é a sintonia e avaliação de desempenho do sistema de controle.

Em geral, os diversos algoritmos de CPBM utilizam diferentes funções de custo para calcular a lei de controle, porém a maioria deles considera como objetivo minimizar o erro entre a saída futura e a referência desejada penalizando o esforço incremental de controle. Assim, a sintonia desses controladores é diretamente dependente das ponderações das variáveis controladas e das manipuladas e também da predição calculada a partir do modelo de predição.

Algumas abordagens de avaliação de controle existentes não permitem definir qual variável controlada tem o pior seguimento a referência e nem o motivo do desempenho ruim. Existem ainda metodologias que auxiliam os projetistas a escolher as ponderações, mas que não garantem que as escolhas feitas são as melhores possíveis.

Por isso a necessidade de métodos de avaliação de desempenho de sistemas de controle MPC é largamente reconhecida no meio industrial. Com base nisso, foram utilizados seis índices, descritos em [13] que avaliam o desempenho e a sintonia do controlador: os Desvios Médios, o Índice de Seguimento de Referência Relativo, o Índice de Supressão de Movimento, o Índice de Controle Relativo, o Índice do Erro de Predição e o Índice de Estabilidade. Estes índices mostram se as variáveis estão seguindo a referência de forma satisfatória e caso elas não estejam, os índices indicam o porquê.

Este trabalho mostra, a partir de simulações de diversos cenários de operação de uma planta real, que os índices são uma ferramenta de grande potencial para avaliação do desempenho do controle e identificação dos problemas que impedem um bom desempenho.

Abstract

Model Predictive Control (MPC) is probably one of the most successful control techniques used in industrial applications. However, this technology has limitations like the tuning procedure and the control system performance evaluation.

The various MPC algorithms propose different cost functions for obtaining the control law, but the general aim is to minimize the error between the future output and the reference signal, penalizing the control effort necessary for doing so. Therefore, these controllers tuning depend on the weighting sequences and the future output.

Some available performance evaluation approaches do not indicate which variable does not follow the reference signal well or why. There are also methodologies that help designers to choose the weighting sequences, but they do not guarantee the best choice as a result.

That is why there is still the need of new evaluation methods. Based on that, six indices were created. They tell if the controlled variables are following the reference and if they are not, why.

This work show, through various scenarios simulations, that the indices are a great tool to analyze the control performance and identify possible problems that prevent a good performance.

Sumário

Lista de Figuras	vi
1 Introdução	1
2 Controle Preditivo de Processos da Indústria de Petróleo e Gás	4
2.1 Elementos do CPBM	5
2.1.1 O modelo de predição	6
2.1.1.1 O modelo do processo	6
2.1.1.2 Modelo das perturbações	9
2.1.1.3 Resposta livre e forçada	10
2.1.2 Função Objetivo	11
2.1.3 Obtenção da lei de controle	13
2.2 Controle por Matriz Dinâmica (DMC)	14
2.2.1 DMC Original	14
2.2.2 DMC Recursivo	17
2.3 DMC Multivariável	19
2.3.1 DMC Recursivo Multivariável	22
2.4 Comentários finais	23
3 Ferramenta de Auxílio a Sintonia Total (FAST MPC)	24
3.1 Cálculo dos índices	27
3.1.1 Desvios Médios	27
3.1.2 Índice de Estabilidade	28
3.1.3 Índices de Seguimento de Referência Relativo	29
3.1.4 Índices Controle Relativo	30

3.1.5	Índices de Supressão de Movimento	31
3.1.6	Índices do Erro de Modelagem	32
3.2	Apresentação Gráfica dos Resultados	32
3.3	Método Proposto para Tomada de Decisão	33
3.3.1	Análise dos Índices de Seguimento Relativos	33
3.3.2	Análise dos Índices de Supressão de Movimento	33
4	Caso de estudo e ferramentas de simulação e controle	35
4.1	UPGN	35
4.1.1	Controle do teor de C2 no GLP - y3	37
4.1.2	Controle do teor de C5 na gasolina natural - y8	39
4.1.3	Controle da abertura da válvula de pressão - y7	40
4.2	BRLumina	40
4.3	Comentários finais	41
5	Implementação do FAST	43
5.1	Comentários finais	44
6	Avaliação dos índices e resultados	45
6.1	Caso zero: cenário inicial	45
6.2	Caso 1: cenários com erros de modelagem	49
6.3	Caso 2: Cenários com alterações na supressão das ações de controle .	50
6.4	Comentários finais	52
7	Capítulo 7: Conclusões e Perspectivas	54
	Referências Bibliográficas	55

Lista de Figuras

4.1	Esquema simplificado da UPGN	35
4.2	Esquema simplificado torre desbutanizadora	42
4.3	Exemplo de cenário do BRLumina	42
6.1	Desvios Médios	47
6.2	Índices de Seguimento Relativo	47
6.3	Índices de Supressão de Movimento e Controle Relativo	48
6.4	Índices de Erro de Modelagem	48
6.5	Índice de Estabilidade	49
6.6	Índices de Erro de Modelagem	51
6.7	Índices de Supressão e Controle Relativo	53

Capítulo 1: Introdução

O controle preditivo baseado em modelo (CPBM) é uma das técnicas de controle moderno que provavelmente teve mais êxito nas aplicações na indústria porque suas estratégias podem ser aplicadas tanto a sistemas monovariáveis como multivariáveis, as restrições nas saídas e nas ações de controle podem ser consideradas no projeto da lei de controle em tempo real e, pela própria definição dos algoritmos, podem ser usadas para controlar processos com atrasos.

Porém, uma das dificuldades encontradas na aplicação de CPBM é a sintonia e avaliação de desempenho do sistema de controle. Em geral, os diversos algoritmos de CPBM utilizam diferentes funções de custo para calcular a lei de controle, porém a maioria deles considera como objetivo minimizar o erro entre a saída futura e a referência desejada penalizando o esforço incremental de controle. Nas funções de custo o erro e o incremento de controle aparecem multiplicados por coeficientes que permitem dar mais ou menos importância a minimização de um ou de outro. Esses coeficientes podem ser sequências ou matrizes de ponderação do erro e do esforço de controle.

Assim, a sintonia desses controladores é diretamente dependente das ponderações das variáveis controladas e das variáveis manipuladas, e também da predição, ou saída futura, calculada a partir do modelo de predição. Por isso, para conseguir o desempenho desejado do controlador são necessários bons modelos de predição e uma boa escolha nas ponderações das variáveis.

Por isso a necessidade de métodos de avaliação de desempenho de sistemas de controle MPC é largamente reconhecida no meio industrial. Algumas abordagens nessa direção baseiam-se na comparação do desempenho do sistema de controle sob análise a um MPC baseado em variância mínima. Entretanto, com essa abordagem não se pode definir qual variável controlada tem o pior seguimento a referência e nem porque ela tem um desempenho ruim. Existem ainda metodologias que auxiliam os projetistas a escolher as de ponderações, levando em consideração restrições

operacionais e custos, por exemplo. Mas essas metodologias não garantem que as escolhas feitas são as melhores possíveis.

Com base nos parâmetros da função custo e na importância de uma boa predição, foram criados cinco índices que avaliam o desempenho e a sintonia do controlador:

1. Desvios Médios
2. Índices de Seguimento de Referência Relativo
3. Índices de Supressão de Movimento
4. Índices de Controle Relativo
5. Índices do Erro de Predição
6. Índices de Estabilidade

O objetivo deste trabalho é validar o funcionamento desses índices através da simulação de diversos cenários de operação no BRLumina, um software da Petrobrás que permite a avaliação do funcionamento do controlador em um ambiente offline. A Unidade de Processamento de Gás Natural Atalaia, em Serjipe, foi a planta escolhida para ser simulada no BRLumina. O controle preditivo implementado nesta unidade é do tipo *Dinamic Matrix Control*.

Através dos índices é possível verificar se as variáveis estão seguindo a referência de forma satisfatória e caso elas não estejam, os índices indicam o porquê. Durante o projeto, foram criados cenários com erros de modelagem, com alterações de sintonia e com ruído, com o intuito de verificar se os índices são de fato capazes de mostrar esses problemas. Os resultados deste trabalho mostram que estes índices são uma ferramenta de grande potencial para avaliação do desempenho do controle e identificação de pontos de melhoria.

Estes índices [13] estão sendo desenvolvidos no projeto de colaboração entre o DAS e a Petrobrás na área de controle avançado. Este projeto de fim de curso foi realizado no Centro de Pesquisas e Desenvolvimento Leopoldo Américo Miguez de Mello (Cenpes) da Petrobrás, no Rio de Janeiro.

A Petrobrás é uma empresa integrada de energia nos setores exploração e produção, refino, comercialização, transporte, petroquímica, distribuição de derivados, gás natural, energia elétrica, gás-química e biocombustíveis. A empresa, que hoje é

líder do setor petrolífero no Brasil, está presente em outros 17 países. E a meta até 2030 é estar entre as 5 maiores empresas de energia do mundo. Para isso, inovação é fundamental e por isso muitos projetos em colaboração com universidades estão sendo realizados no Cenpes, que hoje centraliza as atividades de pesquisa e desenvolvimento da empresa.

O capítulo 2 traz uma revisão da teoria de controle preditivo e dos conceitos usados na formulação dos índices apresentados no capítulo 3. O capítulo 4 explica o processo estudado através dos índices e o *software* de simulação utilizado. O capítulo 5 explica como a ferramenta foi implementada e no capítulo 6 são apresentados os resultados obtidos através das simulações. As conclusões são apresentadas no capítulo 7.

Capítulo 2: Controle Preditivo de Processos da Indústria de Petróleo e Gás

O controle preditivo baseado em modelo (CPBM) é uma das técnicas de controle moderno mais potentes e provavelmente a que teve mais êxito nas aplicações na indústria. As principais causas deste êxito devem-se a que as estratégias de CPBM podem ser aplicadas tanto a sistemas monovariáveis como multivariáveis, as restrições nas saídas e nas ações de controle podem ser consideradas no projeto da lei de controle em tempo real e, pela própria definição dos algoritmos, podem ser usadas para controlar processos com atrasos.

O CPBM não é uma estratégia de controle específica, mas é o nome dado a um conjunto muito grande de métodos de controle que foram desenvolvidos considerando algumas ideias comuns. As características comuns destes sistemas de controle são basicamente:

- usam um modelo explícito do processo para prever a saída ¹ do mesmo num determinado horizonte finito;
- calculam as ações de controle para todo o horizonte a partir da minimização de uma determinada função objetivo;
- o horizonte é deslizante, pelo que, para cada período de amostragem, o horizonte é deslocado um passo para frente, aplica-se unicamente a ação de controle daquele instante e desconsidera-se o resto dos controles dentro do horizonte.

As diferenças entre os diversos algoritmos existentes devem-se basicamente à

¹ Usaremos o termo saída da planta para as variáveis controladas e o termo controle para as variáveis manipuladas

forma de escolher os modelos para o processo e as perturbações, ao tipo de função objetivo e ao procedimento para manipular as restrições e o cálculo do controle.

Muitas técnicas de controle preditivo tem sido aplicadas com êxito na indústria [7]. A maioria dos resultados de aplicação prática de CPBM correspondem à família dos algoritmos que surgiram no ambiente industrial, como o *controle por matriz dinâmica* (“Dynamic Matrix Control”, DMC) [5] e o *controle algorítmico baseado em modelo* (“Model Algorithm Control”, MAC) [17]. Estes algoritmos utilizam modelos de tipo resposta ao impulso ou ao degrau para descrever o processo e modelos bem simples para a descrição das perturbações.

Por outro lado, existe outra família de algoritmos dentro da classe de CPBM que surgiram no meio acadêmico, geralmente relacionados ao controle adaptativo, e que possuem uma série de características diferentes aos do primeiro grupo [6]. Neste segundo grupo, onde devem ser incluídos o *controle preditivo generalizado* (“Generalized Predictive Controller”, GPC) [4], o *controle adaptativo de predição extendida* EPSAC (“Extended Prediction Self Adaptive Control”) [10], o *controle adaptativo de horizonte extendido* EHAC (“Extended Horizon Adaptive Control”) [21] e o *controle preditivo unificado* UPC [19], a planta é representada por uma função de transferência e as perturbações são representadas por um modelo auto-regressivo integrado e de média móvel (normalmente denominado na literatura inglesa modelo ARIMA [9]), enquanto as predições da saída do processo calculam-se usando preditores ótimos.

2.1: Elementos do CPBM

Todos os algoritmos de CPBM possuem os seguintes elementos em comum:

- O modelo de predição
- A função objetivo
- Um método para a obtenção da lei de controle

sendo que as diferentes opções de modelo, função objetivo e método de cálculo do controle geram as diversas versões de controladores propostos na literatura.

2.1.1: O modelo de predição

O modelo de predição é provavelmente o elemento mais importante dentro do controlador, dado que ele deve ser capaz de representar adequadamente a dinâmica do processo, deve permitir o cálculo das predições da saída do processo, ser intuitivo e, ao mesmo tempo, permitir uma análise teórica do sistema.

2.1.1.1: O modelo do processo

As diferentes estratégias de CPBM utilizam diferentes formas para representar as relações entre entradas manipuladas, perturbações e saídas do processo. Em geral, os modelos também incluem uma representação matemática das perturbações e do ruído, assim como dos erros de modelagem. Em geral, o modelo é separado em duas partes: no modelo do processo propriamente dito e no modelo das perturbações; ambos necessários para o cálculo das predições.

Os modelos mais usados para representar ao processo são:

- Resposta Impulsiva. É utilizado no MAC e em casos especiais no GPC e no EPSAC. A relação entrada saída vem dada por:

$$y(t) = \sum_{i=1}^{\infty} h_i u(t-i)$$

onde h_i são as amostras da saída do processo correspondente à aplicação de um impulso na entrada do mesmo. Em geral, como esta sequência é infinita a resposta é truncada para os primeiros M valores, pelo que o modelo somente pode ser usado com plantas estáveis, onde $h_i \rightarrow 0$ quando $i \rightarrow \infty$:

$$y(t) = \sum_{i=1}^M h_i u(t-i) = H(z^{-1})u(t) \quad (2.1)$$

onde $H(z^{-1}) = h_1 z^{-1} + h_2 z^{-2} + \dots + h_N z^{-N}$, e z^{-1} é o operador atraso unitário.

A predição da saída em $t+k$ calculada no instante t (doravante $\hat{y}(t+k | t)$) usando este modelo é calculada como:

$$\hat{y}(t+k | t) = \sum_{i=1}^M h_i u(t+k-i | t) = H(z^{-1})u(t+k | t)$$

Este método é bastante utilizado na prática devido a que oferece como vantagens: (a) é intuitivo; (b) não precisa de conhecimento a-priori do processo para aplicar um método de identificação e pode ser usado em plantas multivariáveis sem acrescentar complexidade, e (c) descreve de maneira simples efeitos mais complexos da dinâmica do processo como atrasos e comportamentos de fase não mínima.

Por outro lado apresenta alguns inconvenientes: (a) não pode ser usado com plantas instáveis e (b) necessita utilizar um grande número de parâmetros para descrever o modelo. Geralmente M pode ser 40 ou 50, valor que pode aumentar ainda mais se o processo tiver um atraso grande.

- Resposta ao degrau. É usado pelo DMC e suas variantes. É similar ao anterior mas usa um degrau unitário como sinal de entrada. Para sistemas estáveis a resposta é:

$$y(t) = y_0 + \sum_{i=1}^{\infty} g_i \Delta u(t-i) = y_0 + G(z^{-1})(1-z^{-1})u(t) \quad (2.2)$$

onde os g_i são as amostras da saída obtida ao aplicar o degrau e $\Delta u(t) = u(t) - u(t-1)$. Considerando o sistema no ponto de operação y_0 a predição pode ser calculada como:

$$\hat{y}(t+k | t) = \sum_{i=1}^{\infty} g_i \Delta u(t+k-i | t)$$

A relação entre este modelo e o de resposta impulsiva é dada por:

$$h_i = g_i - g_{i-1} \quad g_i = \sum_{j=1}^i h_j$$

Resulta, claro, que este modelo tem as mesmas vantagens e inconvenientes que o anterior.

- Função de Transferência. Este modelo é usado no GPC, UPC, EPSAC, EHAC entre outros. Utiliza o conceito de função de transferência $G = B/A$:

$$A(z^{-1})y(t) = B(z^{-1})u(t)$$

onde z^{-1} representa o operador de atraso no tempo ², os polinômios ficam com a seguinte estrutura

$$\begin{aligned} A(z^{-1}) &= 1 + a_1 z^{-1} + a_2 z^{-2} + \dots + a_{na} z^{-na} \\ B(z^{-1}) &= b_1 z^{-1} + b_2 z^{-2} + \dots + b_{nb} z^{-nb} \end{aligned}$$

A predição é calculada como:

$$\hat{y}(t+k | t) = \frac{B(z^{-1})}{A(z^{-1})} u(t+k | t)$$

Esta representação tem como vantagens principais que pode ser usada para plantas instáveis e que precisa, em geral, de poucos parâmetros para descrever o comportamento do sistema (o atraso, por exemplo, pode ser descrito apenas com um parâmetro). Já seu principal inconveniente é a necessidade de conhecer a priori a ordem dos polinômios A e B quando o modelo deve ser identificado a partir de dados experimentais.

- Espaço de estados. É usado no controle preditivo funcional PFC [16] e tem a seguinte representação:

$$\begin{aligned} x(t) &= Mx(t-1) + Nu(t-1) \\ y(t) &= Qx(t) \end{aligned}$$

onde x é o estado e M , N e Q são matrizes de dimensões compatíveis. A predição é calculada como:

$$\hat{y}(t+k | t) = Q\hat{x}(t+k | t) = Q \left[M^k x(t) + \sum_{i=1}^k M^{i-1} Nu(t+k-i | t) \right]$$

Sua principal vantagem é que pode ser usada diretamente para processos multivariáveis. Como inconvenientes, cabe mencionar que, em geral, os estados não tem significado físico, e que na maioria das vezes é necessário o uso de observadores, aumentando assim a complexidade de cálculo do controle.

²neste capítulo z^{-1} também representará a variável complexa associada a transformada Z nos casos que se trabalhe com função de transferência

- Outros modelos. Todos os modelos anteriormente descritos consideram somente o comportamento linear ou linearizado do processo, e, por sua simplicidade, são os mais utilizados. Porém, modelos não lineares também podem ser usados para descrever a dinâmica do processo quando os modelos lineares não geram bons resultados. É importante salientar, entretanto, que a solução do problema nestes casos apresenta alguns inconvenientes adicionais como: (a) a obtenção do modelo do processo se torna mais difícil, e (b) a complexidade dos algoritmos de controle resultantes. Redes neurais [20] ou lógica nebulosa [18] podem ser usadas em algumas aplicações para determinar o modelo de predição.

O CPBM não linear é um campo aberto para pesquisas tanto na área de determinação de modelos como nos procedimentos e algoritmos de otimização para o cálculo do controle.

2.1.1.2: Modelo das perturbações

A escolha de um modelo para as perturbações é tão importante quanto a do processo. O modelo mais utilizado para a descrição de perturbações determinísticas e estocásticas é o conhecido como modelo auto-regressivo integrado de media móvel (Auto-Regressive and Integrated Moving Average (ARIMA)). Neste caso, as diferenças entre a saída do modelo e do processo são modeladas por:

$$\eta(t) = \frac{C(z^{-1})e(t)}{D(z^{-1})}$$

onde o polinômio $D(z^{-1})$ inclui um integrador $\Delta = 1 - z^{-1}$, $e(t)$ é um ruído branco de média zero. Os demais parâmetros dos polinômios C e D são usados para descrever as características estocásticas de n . Este modelo permite representar mudanças aleatórias, “off-sets” e outros fenômenos normalmente encontrados nos meios industriais. Este modelo é usado diretamente no GPC, EPSAC, EHAC e UPC e, com algumas modificações, em outros controladores.

Alguns casos particulares importantes são: (a) o modelo usado em DMC,

$$\eta(t) = \frac{e(t)}{1 - z^{-1}}$$

onde a melhor predição para $\hat{\eta}(t+k | t) = \eta(t)$ dado que $e(t)$ tem média zero; ou (b) o

modelo usado no PFC

$$\eta(t) = \frac{e(t)}{(1 - z^{-1})^2}$$

onde $\hat{\eta}(t + k | t) = \eta(t) + (\eta(t) - \eta(t - 1))k$.

Outras variações destes modelos e estudos sobre o efeito do modelo das perturbações no sistema de controle podem ser encontradas em [1, 14].

2.1.1.3: Resposta livre e forçada

Uma característica comum nos CPBM com modelos lineares, é a utilização dos conceitos de resposta livre e forçada. A ideia é considerar a sequência de controle composta por duas partes:

$$u(t) = u_f(t) + u_c(t)$$

$u_f(t)$ correspondente aos valores passados da entrada e que são mantidos iguais aos valores da variável manipulada:

$$\begin{aligned} u_f(t - j) &= u(t - j) \text{ para } j = 1, 2, \dots \\ u_f(t + j) &= u(t - 1) \text{ para } j = 0, 1, 2, \dots \end{aligned}$$

$u_c(t)$ é zero no passado e igual aos controles a serem aplicados no futuro:

$$\begin{aligned} u_c(t - j) &= 0 \text{ para } j = 1, 2, \dots \\ u_c(t + j) &= u(t + j) - u(t - 1) \text{ para } j = 0, 1, 2, \dots \end{aligned}$$

Desta forma a predição da saída do processo pode ser separada em duas partes: a resposta livre ($y_f(t)$), que corresponde à predição quando a entrada é igualada à $u_f(t)$, e a outra, à resposta forçada ($y_c(t)$), que corresponde as predições quando o controle é igual a $u_c(t)$. Como ser é mostrado adiante, estes conceitos são importantes para a interpretação da forma como o controle é obtido.

2.1.2: Função Objetivo

Em geral, os diversos algoritmos de CPBM utilizam diferentes funções de custo para calcular a lei de controle, porém a maioria deles consideram como objetivo minimizar o erro entre a saída futura (y) e a referência desejada (w) penalizando o esforço incremental de controle Δu .

Assim, a expressão mais geral desta função objetivo para o caso monovariável é:

$$J = \sum_{j=N_1}^{N_2} \delta(j) [\hat{y}(t+j | t) - w(t+j)]^2 + \sum_{j=1}^{N_u} \lambda(j) [\Delta u(t+j-1)]^2 \quad (2.3)$$

Os elementos desta função são:

- **Parâmetros:** N_1 , N_2 , N_u , $\delta(t)$ e $\lambda(t)$. N_1 e N_2 são os horizontes de predição mínimo e máximo, N_u é o horizonte de controle. Os valores destes índices tem uma interpretação clara já que definem os instantes onde deseja-se que a referência siga à saída e onde é importante limitar a ação de controle. Assim, se, por exemplo, N_1 é grande implica que não é importante o erro cometido nos primeiros $N_1 - 1$ instantes e a resposta obtida tenderá a ser suave. No caso particular de sistemas com um atraso de valor d , é lógico escolher $N_1 > d$, já que não haverá resposta do sistema à entrada $u(t)$ até o tempo $t = d$. Variando N_u é possível penalizar durante mais ou menos tempo a ação de controle. Os coeficientes $\delta(j)$ e $\lambda(j)$ são as sequências de ponderação do erro e do esforço de controle e geralmente são escolhidas constantes ou exponenciais ao longo do horizonte. Por exemplo, uma função do tipo:

$$\delta(j) = \alpha^{N_2-j}$$

permite variar a penalização do erro em diferentes partes do horizonte. Assim, para, por exemplo, gerar respostas mais suaves, escolhe-se um de valor α entre 0 e 1 de forma tal que sejam mais penalizados os últimos valores do erro dentro do horizonte.

- **Trajetória de referência:** uma das vantagens do CPBM é a possibilidade de utilizar o conhecimento dos valores futuros da referência (quando disponíveis) para o cálculo do sinal de controle, o que permite, por exemplo que o sistema atinja

mais rapidamente o novo valor desejado. Esta característica torna-se interessante em algumas aplicações como em robótica móvel e manipuladora, em servo-acionamentos e em processos do tipo batelada, onde as referências futuras são conhecidas a priori.

Os valores de $w(t + k)$ utilizados na função objetivo não são necessariamente coincidentes com a referência real do sistema. Normalmente, nas aplicações práticas, utilizam-se estratégias para suavizar as mudanças de referência, de forma similar aos filtros utilizados nas estruturas clássicas de controle com dois graus de liberdade. Uma forma típica para esta lei é:

$$w(t) = r(t) \quad w(t + k) = \alpha w(t + k - 1) + (1 - \alpha)r(t + k) \quad k = 1 \dots N \quad (2.4)$$

onde α é um parâmetro entre 0 e 1. Esta lei representa um filtro passa-baixas de primeira ordem que pode ser ajustado para suavizar mais, α próximo de um, ou menos, α próximo de zero, a forma da resposta. Estas ideias são usadas no GPC e no EPSAC para especificar o comportamento desejado para a malha fechada [3].

- Restrições: Na prática, todos os processos estão sujeitos a restrições tanto nas variáveis de saída como de entrada. Exemplos disto são os limites máximos e mínimos impostos aos atuadores (como por exemplo válvulas), a máxima velocidade de variação de um acionamento (por exemplo servo-acionamentos) ou os valores limites que podem ser atingidos pelas saídas de um sistema devido a questões de segurança. Além disso existem restrições do tipo econômico para o funcionamento do sistema que em geral levaram a escolher pontos de operação muito próximos destes limites. Assim, se o controle é corretamente calculado para trabalhar muito próximo daquele ótimo, a qualidade e a relação custo-benefício do processo produtivo são otimizadas [2]. Por estes motivos, a inclusão das restrições na função objetivo que se deseja minimizar é importante. Neste sentido, todos os algoritmos de CPBM permitem incluí-las no momento da obtenção do mínimo de J considerando um conjunto de equações do tipo:

$$\begin{aligned}
u_{min} &\leq u(t) \leq u_{max} & \forall t \\
du_{min} &\leq u(t) - u(t-1) \leq du_{max} & \forall t \\
y_{min} &\leq y(t) \leq y_{max} & \forall t
\end{aligned}$$

Deve ser mencionado aqui que, nestes casos, a solução do mínimo de J não pode ser obtida analiticamente, e requer uma carga de cálculo bem maior que no caso sem restrições. Apesar da complexidade de cálculo, a capacidade do CPBM de levar as restrições em consideração é o principal motivo do seu sucesso nas aplicações industriais.

O tratamento do CPBM com restrições apresenta diversas dificuldades, tanto teóricas como de implementação. A formulação do problema consiste no correto equacionamento das restrições e num tratamento posterior que é conhecido como “estudo de factibilidade e gestão de restrições”. Este tratamento permite o correto funcionamento do algoritmo de otimização, liberando ou suavizando, quando possível, as restrições. Por outro lado, do ponto de vista da implementação do algoritmo de otimização, as pesquisas estão orientadas à melhoria da eficiência e à minimização dos tempos de cálculo [8]. Finalmente, os problemas de estabilidade destes sistemas de controle somente tem sido resolvidos parcialmente e numerosas pesquisas vem sendo realizadas nos últimos anos (ver [2, 15] e as referências citadas para um estudo mais aprofundado destes problemas).

2.1.3: Obtenção da lei de controle

Em todos os algoritmos de CPBM o objetivo é calcular $u(t+k | t)$ para minimizar J . Para isso é necessário calcular as predições $\hat{y}(t+k | t)$ como função do controle futuro (a partir do método utilizado por cada algoritmo), e substituir na função J . No caso de utilizar um modelo linear e sem restrições, é possível obter uma solução analítica do mínimo de J . Em outro caso a solução é obtida de forma iterativa por algum método de otimização.

Independente do método utilizado, a solução é, em geral, complexa devido ao número de variáveis envolvidas, principalmente quando os horizontes são grandes. Para reduzir os graus de liberdade deste problema alguns algoritmos propõem estruturar a lei de controle. Isto pode ser feito como no DMC, GPC, EPSAC e EHAC, ajustando

o horizonte de controle (N_u), o que implica em zerar as variações do controle após um certo valor no horizonte $N_u < N_2$:

$$\Delta u(t + j - 1) = 0 \quad j > N_u$$

Outra forma de estruturar o controle, que é usada no PFC, consiste em calcular o controle como uma combinação de funções preestabelecidas:

$$u(t + k) = \sum_{i=1}^n \mu_i(t) B_i(k) \quad (2.5)$$

onde os B_i são escolhidos de acordo com o tipo de processo e de referência.

2.2: Controle por Matriz Dinâmica (DMC)

Nesta seção será discutido o algoritmo preditivo chamado Controle por Matriz Dinâmica (DMC), um dos algoritmos mais difundidos na indústria e usado como base para o controlador CPM da Petrobras. Inicialmente será mostrado o algoritmo original do DMC proposto em [5], e depois será introduzido o DMC com implementação recursiva, proposto em [12], que modifica como a resposta livre é calculada de forma a obter um algoritmo mais simples de ser implementado e com a vantagem de não afetar o controlador original do DMC.

2.2.1: DMC Original

O algoritmo DMC utiliza os coeficientes da resposta do degrau do sistema para calcular as previsões:

$$\hat{y}(t + k|t) = \sum_{i=1}^{\infty} g_i \Delta u(t + k - i) + \eta(t + k|t) \quad (2.6)$$

onde $\eta(t + k|t)$ é o erro de previsão no instante $t + k$. Como, em geral, não é possível determinar o erro de previsão futuro, supõe-se que o erro de previsão se manterá constante, então $\eta(t + k|t) = \eta(t|t) = y(t) - y_o(t|t)$, onde y_o é a previsão em malha aberta, ou seja, sem correções. Substituindo o erro de previsão na Eq. (2.6), e separando os termos do somatório que dependem das ações futuras de controle tem-se

$$\begin{aligned}
\hat{y}(t+k|t) &= \sum_{i=1}^k g_i \Delta u(t+k-i) + \sum_{i=1}^{\infty} g_{k+i} \Delta u(t-i) + y(t) - \sum_{i=1}^{\infty} g_i \Delta u(t-i) \\
\hat{y}(t+k|t) &= \sum_{i=1}^k g_i \Delta u(t+k-i) + \sum_{i=1}^{\infty} (g_{k+i} - g_i) \Delta u(t-i) + y(t)
\end{aligned} \tag{2.7}$$

O somatório infinito presente na equação anterior pode ser truncado após M termos, isto porque $g_{k+i} - g_i \cong 0, \forall i > M$. Isto resulta na seguinte equação de predição para o DMC:

$$\hat{y}(t+k|t) = \sum_{i=1}^k g_i \Delta u(t+k-i) + \sum_{i=1}^M (g_{k+i} - g_i) \Delta u(t-i) + y(t) \tag{2.8}$$

$$\tag{2.9}$$

Considerando um horizonte de predição de N amostras e um horizonte de controle de N_u , pode-se escrever as predições futuras de forma matricial:

$$\hat{\mathbf{y}} = \mathbf{G}\mathbf{u} + \mathbf{I}\Delta\mathbf{u}(t-1) + \mathbf{1}_N y(t) \tag{2.10}$$

onde $\mathbf{1}_N$ é um vetor com N linhas cujos elementos são todos iguais a 1,

$$\mathbf{I}\Delta\mathbf{u}(t-1) = \begin{bmatrix} (g_2 - g_1) & (g_3 - g_2) & \dots & (g_{M+1} - g_M) \\ (g_3 - g_1) & (g_4 - g_2) & \dots & (g_{M+2} - g_M) \\ \vdots & \vdots & \dots & \vdots \\ (g_{N+1} - g_1) & (g_{N+2} - g_2) & \dots & (g_{N+M} - g_M) \end{bmatrix} \begin{bmatrix} \Delta u(t-1) \\ \Delta u(t-2) \\ \vdots \\ \Delta u(t-M) \end{bmatrix},$$

$$\mathbf{G}\mathbf{u} = \begin{bmatrix} g_1 & 0 & \dots & 0 \\ g_2 & g_1 & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ g_N & g_{N-1} & \dots & g_{N-N_u} \end{bmatrix} \begin{bmatrix} \Delta u(t) \\ \Delta u(t+1) \\ \vdots \\ \Delta u(t+N_u-1) \end{bmatrix},$$

e $\hat{\mathbf{y}} = [\hat{y}(t+1|t), \dots, \hat{y}(t+N|t)]^T$.

Nota-se que na matriz \mathbf{I} existem coeficientes g_i com índice maior que M , quando isto acontece, faz-se $g_i = g_M, \forall i > M$.

A Eq. (2.10) pode ser reescrita da forma:

$$\hat{y} = \mathbf{G}u + \mathbf{f}_r \quad (2.11)$$

onde $\mathbf{f}_r = \mathbf{I}\Delta u(t-1) + \mathbf{1}_N y(t)$ é a resposta livre do sistema.

Nesta equação pode-se observar que se as condições iniciais são nulas a resposta livre é zero, e que se for aplicado um degrau unitário em u ,

$$\Delta u(t) = 1, \Delta u(t+1) = 0, \dots, \Delta u(t+N-1) = 0$$

a sequência de saída $[\hat{y}(t+1), \hat{y}(t+2), \dots, \hat{y}(t+N)]^T$ será igual à primeira coluna de \mathbf{G} . Isto implica que a primeira coluna de \mathbf{G} pode ser calculada a partir da resposta ao degrau do sistema. Na prática é interessante escolher um horizonte de controle $N_u < N$ (normalmente $N_u = N/5$ gera resultados satisfatórios) o que simplifica o problema de controle pois diminui os graus de liberdade. Neste caso na equação de cálculo das predições a matriz \mathbf{G} terá dimensão $N \times N_u$ e o vetor u dimensão $N_u \times 1$.

Para calcular o mínimo de J é conveniente escrever a expressão (2.3) como:

$$J = (\mathbf{G}u + \mathbf{f}_r - \mathbf{w})^T \mathbf{Q}_y (\mathbf{G}u + \mathbf{f}_r - \mathbf{w}) + u^T \mathbf{Q}_u u \quad (2.12)$$

onde \mathbf{Q}_y e \mathbf{Q}_u são matrizes diagonais com os valores das ponderações na diagonal.

$$\mathbf{w} = \begin{bmatrix} w(t+d+1) & w(t+d+2) & \dots & w(t+d+N) \end{bmatrix}^T$$

A equação (2.12) pode ser escrita como uma forma quadrática:

$$J = \frac{1}{2} u^T \mathbf{H} u + \mathbf{b}^T u + \mathbf{f}_0 \quad (2.13)$$

onde:

$$\begin{aligned}
\mathbf{H} &= 2(\mathbf{G}^T \mathbf{G} + \lambda \mathbf{I}) \\
\mathbf{b}^T &= 2(\mathbf{f}_r - \mathbf{w})^T \mathbf{G} \\
\mathbf{f}_0 &= (\mathbf{f}_r - \mathbf{w})^T (\mathbf{f}_r - \mathbf{w})
\end{aligned}$$

O mínimo de J pode ser calculado, quando não há restrições, igualando o gradiente de J a zero. Assim, o controle pode ser calculado através da equação a seguir:

$$\mathbf{u} = -\mathbf{H}^{-1} \mathbf{b} = (\mathbf{G}^T \mathbf{G} + \lambda \mathbf{I})^{-1} \mathbf{G}^T (\mathbf{w} - \mathbf{f}_r) \quad (2.14)$$

Como o algoritmo é de horizonte deslizante, unicamente o primeiro sinal de controle é aplicado (primeiro elemento do vetor \mathbf{u}), assim a lei de controle final é:

$$\Delta u(t) = \mathbf{K}(\mathbf{w} - \mathbf{f}_r) \quad (2.15)$$

onde \mathbf{K} é a primeira linha da matriz $(\mathbf{G}^T \mathbf{G} + \lambda \mathbf{I})^{-1} \mathbf{G}^T$ e \mathbf{w} o vetor de referencias futuras.

2.2.2: DMC Recursivo

Em [12], demonstrou-se a propriedade recursiva do DMC, que seria apresentada a seguir. As predições de malha aberta em $t+k$ dado as informações em t e $t-1$ são dadas a seguir:

$$\begin{aligned}
y_o(t+k|t) &= \sum_{i=k+1}^{\infty} g_i \Delta u(t+k-i) \\
y_o(t+k|t-1) &= \sum_{i=k+2}^{\infty} g_i \Delta u(t+k-i)
\end{aligned}$$

A diferença entre a predição de malha aberta em $t+k$ dado t , e em $t+k$ dado $t-1$, é apenas a ação de controle nova $\Delta u(t-1)$ que não se conhecia em $t-1$. Subtraindo as equações anteriores:

$$\begin{aligned}
y_o(t+k|t) - y_o(t+k|t-1) &= g_{k+1}\Delta u(t-1) + \sum_{i=k+2}^{\infty} g_i\Delta u(t+k-i) \\
&\quad - \sum_{i=k+2}^{\infty} g_i\Delta u(t+k-i) \\
y_o(t+k|t) &= g_{k+1}\Delta u(t-1) + y_o(t+k|t-1)
\end{aligned}$$

A utilização do DMC recursivo é feita da seguinte forma: mantém-se em memória um vetor com M elementos: $\mathbf{Y}_{livre} = [y_o(t|t-1), \dots, y_o(t+M-1|t-1)]^T$. Seus elementos são as repostas livres dadas as ações de controle conhecidas até o instante $t-1$. Ao iniciar o controlador DMC no instante t_0 , dado que o sistema encontra-se em regime permanente, considera-se que as predições de malha aberta sejam constantes e iguais ao valor de $y(t_0)$.

Ao iniciar a execução do algoritmo DMC no instante t , é preciso atualizar o vetor de resposta livre pois o incremento da ação de controle $\Delta u(t-1)$ agora é conhecido:

$$\mathbf{Y}_{livre} = \mathbf{Y}_{livre} + \begin{bmatrix} g_1 \\ g_2 \\ \vdots \\ g_M \end{bmatrix} \Delta u(t-1)$$

Assim, obtém-se o vetor \mathbf{Y}_{livre} atualizado. Após obter o novo sinal de controle $u(t)$, é preciso “deslocar” os valores dentro do vetor \mathbf{Y}_{livre} , isto porque no instante posterior $t+1$, serão precisas as repostas livres de $t+1$ até $t+M$ baseadas nos dados até t . Então, o primeiro elemento é descartado pois é a predição relativa ao instante t que já passou. O problema é que, ao se fazer este deslocamento, o último elemento, no caso a predição em $y(t+M|t)$, é desconhecida. Porém, no caso estável, $y_o(t+M|t) \cong y_o(t+M-1|t)$, assim, o novo vetor \mathbf{Y}_{livre} será dado por:

$$\mathbf{Y}_{livre} = \begin{bmatrix} y_o(t+1|t) \\ y_o(t+2|t) \\ \vdots \\ y_o(t+M-1|t) \\ y_o(t+M-1|t) \end{bmatrix}$$

A condição $y_o(t+M|t) \cong y_o(t+M-1|t)$ é mostrada a seguir:

$$\begin{aligned}
y_o(t + M - 1|t) &= \sum_{i=M}^{\infty} g_i \Delta u(t + M - 1 - i) \\
y_o(t + M|t) &= \sum_{i=M+1}^{\infty} g_i \Delta u(t + M - i) = \sum_{i=M}^{\infty} g_{i+1} \Delta u(t + M - 1 - i) \\
y_o(t + M|t) - y_o(t + M - 1|t) &= \sum_{i=M}^{\infty} (g_{i+1} - g_i) \Delta u(t + M - 1 - i)
\end{aligned}$$

Como $g_{i+1} - g_i \cong 0, \forall i > M$, tem-se que $y_o(t + M|t) \cong y_o(t + M - 1|t)$, como se queria demonstrar.

Assim, o cálculo da resposta livre considerada no DMC-recursivo é dado da seguinte forma:

$$\mathbf{f}_r = \begin{bmatrix} y_o(t + 1|t) \\ \vdots \\ y_o(t + N|t) \end{bmatrix} + \mathbf{1}_N (y(t) - y_o(t|t)) \quad (2.16)$$

Utilizando esta forma de implementação, os cálculos necessários para obter a resposta livre se tornam mais simples, não sendo necessário o armazenamento dos incrementos passados de controle. Como este procedimento só altera o modo de calcular a resposta livre, o restante do algoritmo de controle não é modificado.

2.3: DMC Multivariável

O algoritmo para o caso monovariável, apresentado na seção 2.2.1, pode ser facilmente estendido para o caso multivariável. Para um sistema com m entradas e n saídas, as predições são calculadas da seguinte forma:

$$\left\{ \begin{array}{lcl} \hat{y}_1(t+k|t) & = & \sum_{i=1}^{\infty} g_{11,i} \Delta u_1(t+k-i) + \sum_{i=1}^{\infty} g_{12,i} \Delta u_2(t+k-i) + \\ & & \dots + \sum_{i=1}^{\infty} g_{1m,i} \Delta u_m(t+k-i) + \eta_1(t+k|t) \\ \vdots & = & \vdots \\ \hat{y}_n(t+k|t) & = & \sum_{i=1}^{\infty} g_{n1,i} \Delta u_1(t+k-i) + \sum_{i=1}^{\infty} g_{n2,i} \Delta u_2(t+k-i) + \\ & & \dots + \sum_{i=1}^{\infty} g_{nm,i} \Delta u_m(t+k-i) + \eta_n(t+k|t) \end{array} \right. \quad (2.17)$$

onde $\hat{y}_h(t+k|t)$ é a predição da h -ésima saída no instante $t+k$ dado os dados em t , u_j a j -ésima entrada, $g_{hj,i}$ é o i -ésimo coeficiente da resposta ao degrau da saída h em relação à entrada j , e η_h é o erro de predição que é calculado de maneira idêntica ao caso monovariável, ou seja, $\eta_h(t+k|t) = y_h(t+k) - \hat{y}_h(t+k|t)$.

A predição de malha aberta sem correção da saída h , $y_{oh}(t|t)$, é dada por

$$y_{oh}(t|t) = \sum_{i=1}^{\infty} g_{h1,i} \Delta u_1(t-i) + \sum_{i=1}^{\infty} g_{h2,i} \Delta u_2(t-i) + \dots + \sum_{i=1}^{\infty} g_{hm,i} \Delta u_m(t-i), \quad (2.18)$$

substituindo a equação anterior na equação 2.17, obtém-se a predição de uma forma similar ao apresentado no caso monovariável, excetuando o fato de agora haver mais variáveis de controle:

$$\begin{aligned} \hat{y}_h(t+k|t) &= \sum_{i=1}^k g_{h1,i} \Delta u_1(t+k-i) + \dots + \sum_{i=1}^k g_{hm,i} \Delta u_m(t+k-i) \\ &+ \sum_{i=1}^{\infty} (g_{h1,k+i} - g_{h1,i}) \Delta u_1(t-i) + \dots + \sum_{i=1}^{\infty} (g_{hm,k+i} - g_{hm,i}) \Delta u_m(t-i) \\ &+ y(t) \end{aligned}$$

Assim como apresentado anteriormente, os somatórios infinitos podem ser truncados após M termos pois, para sistemas estáveis, $g_{hj,k+i} - g_{hj,i} \cong 0$, $\forall i > M$.

Rearranjando os resultados em forma matricial e considerando, sem perda de

generalidade, um horizonte de predição N e de controle N_u comum a todas as entradas, as predições da h -ésima saída podem ser escritas como a seguir:

$$\begin{aligned} \hat{\mathbf{y}}_h = \begin{bmatrix} \hat{y}_h(t+1|t) \\ \vdots \\ \hat{y}_h(t+N|t) \end{bmatrix} &= [\mathbf{G}_{h1} \ \mathbf{G}_{h2} \ \dots \ \mathbf{G}_{hm}] \begin{bmatrix} \Delta u_1(t) & \dots & \Delta u_m(t) \\ \vdots & \vdots & \vdots \\ \Delta u_1(t+N_u-1) & \dots & \Delta u_m(t+N_u-1) \end{bmatrix} \\ &+ [\mathbf{I}_{h1} \ \mathbf{I}_{h2} \ \dots \ \mathbf{I}_{hm}] \begin{bmatrix} \Delta u_1(t-1) & \dots & \Delta u_m(t-1) \\ \vdots & \vdots & \vdots \\ \Delta u_1(t-M) & \dots & \Delta u_m(t-M) \end{bmatrix} \\ &+ \mathbf{1}_N y_h(t), \end{aligned} \quad (2.19)$$

ou, de forma mais compacta,

$$\hat{\mathbf{y}}_h = [\mathbf{G}_{h1} \ \mathbf{G}_{h2} \ \dots \ \mathbf{G}_{hm}] \mathbf{u} + [\mathbf{I}_{h1} \ \mathbf{I}_{h2} \ \dots \ \mathbf{I}_{hm}] \Delta \mathbf{u}(t-1) + \mathbf{1}_N y_h(t),$$

onde as matrizes \mathbf{G}_{hj} e \mathbf{I}_{hj} são calculadas de maneira idêntica ao caso monovariável.

Combinando as predições de todas as saídas, obtém-se a seguinte representação matricial:

$$\hat{\mathbf{y}} = \mathbf{G} \mathbf{u} + \mathbf{I} \Delta \mathbf{u}(t-1) + \mathbf{I}_y \mathbf{y}(t) \quad (2.20)$$

onde $\hat{\mathbf{y}} = [\hat{\mathbf{y}}_1^T, \dots, \hat{\mathbf{y}}_h^T]^T$, $\mathbf{y} = [y_1(t), \dots, y_h(t)]$, e

$$\mathbf{G} = \begin{bmatrix} \mathbf{G}_{11} & \dots & \mathbf{G}_{1m} \\ \vdots & \vdots & \vdots \\ \mathbf{G}_{h1} & \dots & \mathbf{G}_{hm} \end{bmatrix}, \mathbf{I} = \begin{bmatrix} \mathbf{I}_{11} & \dots & \mathbf{I}_{1m} \\ \vdots & \vdots & \vdots \\ \mathbf{I}_{h1} & \dots & \mathbf{I}_{hm} \end{bmatrix},$$

$$\mathbf{I}_y = \begin{bmatrix} \mathbf{1}_N & 0 & \dots & 0 \\ 0 & \mathbf{1}_N & \dots & 0 \\ 0 & 0 & \dots & \mathbf{1}_N \end{bmatrix}.$$

Deve ser lembrado que a resposta livre é dada por $\mathbf{f}_r = \mathbf{I} \Delta \mathbf{u}(t-1) + \mathbf{I}_y \mathbf{y}(t)$,

que é um vetor de ordem $h \cdot N \times 1$.

2.3.1: DMC Recursivo Multivariável

A propriedade recursiva do DMC apresentada na seção 2.2.2 continua válida no caso multivariável, com a diferença que agora será necessário manter h vetores de respostas livres correspondentes a cada saída.

Da mesma forma que no caso monovariável, mantém-se em memória h vetores com M elementos: $\mathbf{Y}_{h,livre} = [y_{oh}(t|t-1), \dots, y_{oh}(t+M-1|t-1)]^T$. Seus elementos são as respostas livres dadas as ações de controle conhecidas até o instante $t-1$. Ao iniciar o controlador DMC no instante t_0 , dado que o sistema encontra-se em regime permanente, considera-se que as predições de malha aberta para todas as saídas sejam constantes e iguais ao valor de $y_h(t_0)$.

Depois de iniciar a execução do algoritmo DMC no instante t , é preciso atualizar o vetor de resposta livre com o incremento das ações de controle $\Delta u_j(t-1)$, $j = 1, \dots, m$, que agora são conhecidas:

$$\mathbf{Y}_{l,livre} = \mathbf{Y}_{l,livre} + \begin{bmatrix} g_{h1,1} \\ g_{h1,2} \\ \vdots \\ g_{h1,M} \end{bmatrix} \Delta u_1(t-1) + \dots + \begin{bmatrix} g_{hm,1} \\ g_{hm,2} \\ \vdots \\ g_{hm,M} \end{bmatrix} \Delta u_m(t-1)$$

Assim, obtém-se o vetor $\mathbf{Y}_{h,livre}$ atualizado. Após obter o novo sinal de controle $u(t)$, é preciso “deslocar” os valores dentro do vetor $\mathbf{Y}_{h,livre}$, isto porque no instante posterior $t+1$, serão precisos as repostas livres de $t+1$ até $t+M$ baseadas nos dados até t . Então, o primeiro elemento é descartado pois é a predição relativa ao instante t que já passou. O problema é que, ao se fazer este deslocamento, o último elemento, no caso a predição em $y_h(t+M|t)$, é desconhecida. Porém, no caso estável, $y_{oh}(t+M|t) \cong y_{oh}(t+M-1|t)$, assim, o novo vetor $\mathbf{Y}_{h,livre}$ será dado por:

$$\mathbf{Y}_{H,livre} = \begin{bmatrix} y_{oh}(t+1|t) \\ y_{oh}(t+2|t) \\ \vdots \\ y_{oh}(t+M-1|t) \\ y_{oh}(t+M-1|t) \end{bmatrix}$$

Desta forma, as predições no DMC recursivo multivariável são dadas por

$$\hat{\mathbf{y}} = \mathbf{G}\mathbf{u} + \mathbf{f}_r. \quad (2.21)$$

Considerando que $\mathbf{y}_{oh} = [y_{oh}(t+1), \dots, y_{oh}(t+N)]$, a resposta livre \mathbf{f}_r é dada por

$$\mathbf{f}_r = \begin{bmatrix} y_{o1} \\ \vdots \\ y_{oh} \end{bmatrix} + \mathbf{I}_y \begin{bmatrix} (y_1(t) - y_{o1}(t)) & \dots & (y_l(t) - y_{oh}(t)) \end{bmatrix}. \quad (2.22)$$

2.4: Comentários finais

Neste capítulo foi feita uma revisão da teoria de controle preditivo e dos conceitos usados na formulação dos índices que serão apresentados no capítulo 3. Além disso, também é apresentada a teoria do controle por matriz dinâmica que é o tipo de controle preditivo usado na unidade de processamento analisada neste projeto, descrita no capítulo 4.

Capítulo 3: Ferramenta de Auxílio a Sintonia Total (FAST MPC)

O desenvolvimento da FAST MPC faz parte de uma dissertação de mestrado [13] desenvolvida no projeto de pesquisa e desenvolvimento "Algoritmos para Identificação e Controle Preditivo Não Linear de Processos da Indústria do Petróleo de Gás Natural". Este é um projeto do Departamento de Automação e Sistemas em colaboração com o Cenpes da Petrobrás.

Como o objetivo deste trabalho é validar a metodologia proposta através de um estudo de caso, este capítulo traz uma explicação detalhada do cálculo dos índices e da análise do desempenho e da sintonia do controle. O conteúdo deste capítulo é baseado em relatórios técnicos do projeto e outros materiais internos.

Uma das dificuldades encontradas na aplicação de Controle Preditivo baseado em Modelo é avaliação da sintonia e do desempenho do sistema de controle. Por isso a necessidade de métodos de avaliação de desempenho de sistemas de controle MPC é largamente reconhecida no meio industrial. Algumas abordagens nessa direção baseiam-se na comparação do desempenho do sistema de controle sob análise a um MPC baseado em variância mínima. Entretanto, com essas abordagens não se pode definir qual variável controlada tem o pior seguimento a referência, porque ela tem um desempenho ruim ou onde modificar a sintonia do controlador para atingir um determinado objetivo.

Para conseguir o desempenho desejado do controlador são necessários bons modelos de predição e uma boa escolha nas ponderações das variáveis, já que a sintonia do controlador é diretamente dependente das matrizes de ponderação das variáveis controladas Q_y e das variáveis manipuladas Q_u , e também da predição \bar{Y} calculada a partir do modelo de predição.

A equação 3.1 mostra a função custo na forma para sistemas multivariáveis, onde \bar{Y} é a predição da variável controlada do sistema, $W(k)$ é a referência ou valor

desejado da variável controlada (*target*), $\Delta U(k)$ é a variação do sinal de controle, Q_y e Q_u são matrizes de ponderação escolhidas arbitrariamente pelo projetista. As matrizes M_y e M_u são matrizes que realizam a normalização das variáveis controladas e manipuladas. Esta normalização pode ser realizada com o valor máximo esperado para cada variável ou com o range ($x_{max} - x_{min}$), por exemplo. Neste trabalho será definido um valor U_n e Y_n como valores normalizados onde $U_n = u_{ss}$ e $Y_n = w$.

$$J = [\bar{\mathbf{Y}} - \mathbf{W}]^T \mathbf{M}_y^T \mathbf{Q}_y \mathbf{M}_y [\bar{\mathbf{Y}} - \mathbf{W}] + \Delta \mathbf{U}^T \mathbf{M}_u^T \mathbf{Q}_u \mathbf{M}_u \Delta \mathbf{U} \quad (3.1)$$

Com base nos parâmetros da função custo e na importância de uma boa predição, foram criados seis índices que avaliam o desempenho e a sintonia do controlador:

1. Índices de Avaliação:

- Desvios Médios;
- Índices de Estabilidade.

2. Índices de Sintonia:

- Índices de Seguimento Relativos;
- Índices de Controle Relativos;
- Índices de Supressão de Movimento;
- Índices de Erro de Modelagem.

Os Índices de Avaliação serão utilizados para analisar o desempenho da planta de forma global e verificar a possibilidade de melhoria das respostas das variáveis controladas. Já os Índices de Sintonia serão utilizados para analisar o ajuste das ponderações Q_y e Q_u da função custo e os modelos utilizados. Os Índices de Erro de Modelagem e os Desvios Médios são os únicos índices que podem ser analisados como um indicador, ou seja, seus valores tem uma interpretação física real independente. Os outros índices não tem sentido analisados isoladamente e devem ser comparados com todos os índices das demais variáveis.

Os índices, analisados em conjunto, indicam como o controlador está tratando cada variável em relação as outras, permitindo uma análise e avaliação da sintonia do controlador MPC e fornecendo uma base sólida para a localização dos principais problemas relacionados com as ponderações da função custo utilizada ou com os modelos de predição. O resultado dessa avaliação visa auxiliar a tomada de decisão quanto

a modificar as ponderações da função custo do controlador MPC ou re-identificar os modelos de predição utilizados.

Os Desvios Médios e os Índices de Seguimento Relativos não ponderados são os índices que avaliam a qualidade do sistema de controle MPC e servem como ponto de partida para as análises do desempenho do MPC. Como estes índices são calculados com o erro de seguimento de referência, a variável controlada com menor índice será aquela que está fazendo o melhor seguimento de referência. Os Desvios Médios apresentam uma a média absoluta do erro de seguimento de referência em porcentagem de cada variável controlada enquanto os Índices de Seguimento Relativos mostram uma visão percentual relativa ao somatório de todos erros individuais para o caso ponderado e não ponderado. Em um sistema sob controle é natural que algumas variáveis controladas tenham maior importância econômica que outras. Uma variável que representa uma concentração, por exemplo, pode ter mais necessidade de seguir uma referência do que uma variável pressão que está dentro dos seus limites aceitáveis. Assim, se a concentração apresenta um índice de seguimento pior do que a pressão, alguma ação precisa ser tomada para melhorar o quadro.

Para identificar onde atuar para melhorar o seguimento de referência de uma variável controlada foram criados os índices de seguimento relativos para saber como atuar nas ponderações Q_y , índices de erro de modelagem para verificar a qualidade dos modelos de predição, índices de ação de controle relativos e supressão de movimento para verificar como atuar nas ponderações Q_u . Os índices de seguimento e de controle, que são baseados em uma parcela da função custo, são calculados para os casos com e sem ponderação. Isso permite comparar o efeito da ponderação com o resultado verificado nas medições reais. No caso sem ponderação pode-se ver como o sistema está funcionando na realidade e no caso ponderado pode-se ver a visão que o controle MPC tem do funcionamento do sistema para calcular as futuras ações de controle.

Com uma adequada interpretação desses índices deverá ser possível identificar:

- Quais variáveis controladas devem ter seus seguimentos de referência melhorados,
- Onde deve-se atuar para obter essas melhorias.

3.1: Cálculo dos índices

A cada instante de tempo k do controle são calculados os índices Instantâneos a partir das equações 3.2, 3.6, 3.8, 3.10, 3.11, 3.12, mostradas a seguir. Como o objetivo é obter valores que refletem o comportamento do sistema ao longo de um determinado tempo, calcula-se a média dos índices Instantâneos através de um algoritmo recursivo.

Neste algoritmo não há necessidade do cálculo de N e pode-se ainda escolher o tempo da janela de medições utilizadas para o cálculo da média, N_{media} , e a influência dos elementos dentro da janela são ponderados por um fator de esquecimento. Ou seja, o índice calculado no instante $k - N_{media} - 1$ tem efeito zero sobre o cálculo da média. Já a influência no cálculo da média cresce desde 0 até 1 para os índices instantâneos calculados em $k - N_{media} - 1$ até k .

A média recursiva é calculada com o seguinte pseudo-código:

Defina: $x = \frac{5}{N_{media}}$ e $I_{y_medio}^i = 0$

se $k = 1$:

$$Den(k) = 1$$

$$I_{y_medio}^i(k) = I_{y_inst}^i(k)$$

senão:

$$Den(k) = Den(k - 1) \cdot e^{-x} + 1$$

$$I_{y_medio}^i(k) = \frac{e^{-x} \cdot I_{y_medio}^i(k - 1) \cdot Den(k - 1) + I_{y_inst}^i(k)}{Den(k)}$$

Todos os valores são normalizados entre 0 e 1 onde é possível observar a influência da sintonia do MPC no sistema para cada variável em comparação com as outras em uma mesma amplitude e a normalização utilizada é a mesma da função custo apresentada.

3.1.1: Desvios Médios

Estes índices avaliam a qualidade do seguimento de referência das variáveis controladas. Seu valor representa o desvio médio do erro de seguimento em porcentagem e pode ser analisado individualmente. Nesse caso, não se calcula relativamente os índices pois não se tem a intenção de analisar as ponderações Q_y , mas a possibilidade de melhorar a resposta da variável controlada com a intenção de diminuir esse

erro. A equação 3.2 mostra esse cálculo.

$$D_{y-inst}^i(k) = 100 \cdot \frac{\|w^i(k) - y^i(k)\|}{w^i(k)} \quad (3.2)$$

Ao final do período de análise teremos $D_{y-medio}^i$ para cada variável controlada. A partir desse valor serão montados dois tipos de índices diferentes: Desvios Médios Individuais e o Desvio Médio Total. Os Desvios Médios Individuais D_{y-ind}^i serão iguais ao valor final de $D_{y-medio}^i$ para cada variável controlada. E o Desvio Médio Total será o somatório desses índices individuais dividido pelo número de variáveis controladas n . Como mostrado na equação 3.3.

$$D_y^i = \frac{\sum_{i=1}^n D_{y-ind}^i}{n} \quad (3.3)$$

Esse Desvio Médio Total ajudará o projetista a saber se as mudanças feitas no projeto do controlador diminuíram o erro médio de seguimento de referência das variáveis controladas, o que representa uma melhoria da resposta do sistema. Os Desvios Médios Individuais são analisados quando se tem interesse maior no seguimento de alguma variável em particular. É o caso quando algumas variáveis do processo tem grande importância econômica, por exemplo.

3.1.2: Índice de Estabilidade

Esse índice avalia o quanto cada variável controlada pode melhorar em desempenho no seguimento da referência sem levar o sistema para a instabilidade. Utilizados em conjunto com os índices de Seguimento Individuais e os índices de Supressão de Movimento auxiliam o projetista a melhorar o desempenho global do sistema. Considerando que o desempenho final de um sistema de controle é frequentemente obtido considerando o compromisso com seguimento de referência e estabilidade, é preciso saber se uma variável controlada está próxima da sua região de instabilidade. A equação 3.6 foi desenvolvida com base no teorema da estabilidade de Lyapunov [11].

Pelo teorema da estabilidade de Lyapunov, uma função $L(t) : \mathbb{R}^n \rightarrow \mathbb{R}$ representada pela equação 3.4 é dita ser positiva definida se atende os requisitos expostos na equação 3.5. O que pode ser facilmente provado com a equação proposta com o valor dos erros de seguimento de referência das variáveis controladas e^i normalizado pelas referências w^i .

$$L(t) = \frac{1}{2} \cdot \left(\frac{e^i(t)}{w^i} \right)^2 \quad (3.4)$$

$$L(0) = 0 \quad \text{e} \quad L > 0 \quad \text{para} \quad \forall \quad e^i \neq 0 \quad (3.5)$$

Como a energia dos estados do sistema precisa decrescer ao longo do tempo, sua derivada deve ser negativa $\frac{\partial L(t)}{\partial t} < 0$. Portanto, para a derivada é esperado um valor negativo. Sabe-se que quanto maior o valor absoluto dessa função, mais rapidamente o sistema decresce sua energia e 'mais' estável será o sistema. E quando o valor se aproxima de zero ocorre a situação inversa. Baseado nessas conclusões foi criado o Índice de Estabilidade, apresentado na equação 3.6. O objetivo desse índice é mostrar o quanto cada variável controlada está perto da sua região de instabilidade.

$$I_{est_inst}^i(k) = \frac{e^i(k)}{w^i(k)^2} \cdot (e^i(k) - e^i(k-1)) - \frac{e^i(k)^2}{w^i(k)^3} \cdot (w^i(k) - w^i(k-1)) \quad (3.6)$$

A geração deste índice é feita calculando uma média recursiva acumulada ao longo do período de análise, como a utilizada nos índices anteriores. Seu valor médio $I_{est_medio}^i$ ao final do período de análise será o índice a ser analisado. Para efeito demonstrativo em uma escala similar aos outros índices, foi usado seu valor em potenciação como a equação 3.7 onde α é um valor escolhido para determinar a sensibilidade da variação entre os índices (normalmente se utiliza o valor 100 ou 1000). Portanto, conclui-se que quanto mais próximo de 0 este valor mais perto de sua região de instabilidade essa variável se encontra.

$$I_{est}^i = 10^{\alpha} \sqrt{-I_{est_medio}^i} \quad (3.7)$$

3.1.3: Índices de Seguimento de Referência Relativo

Estes índices avaliam as variáveis controladas do sistema quanto a qualidade de seu seguimento de referência. Baseado na parcela de erro de seguimento de referência $[\tilde{\mathbf{Y}} - \mathbf{W}]^T \mathbf{M}_y^T \mathbf{Q}_y \mathbf{M}_y [\tilde{\mathbf{Y}} - \mathbf{W}]$ da função custo apresentada na equação 3.1, foi montada a equação 3.8. Onde $y^i(k)$ é o valor medido da variável controlada i e $w^i(k)$ sua referência no instante de amostragem k . O valor é normalizado pela referência $w^i(k)$ para permitir a comparação com as outras variáveis controladas. Nota-se que esse valor indica o erro quadrático percentual da variável controlada normalizado. A

normalização aqui realizada é idêntica aquela feita pela função custo apresentada na equação 3.1 mas, caso seja necessário, outras formas de normalização (*scaling*) devem ser implementadas para evitar a divisão por zero.

$$I_{y_inst}^i(k) = \left(100 \cdot \frac{w^i(k) - y^i(k)}{w^i(k)} \right)^2 \cdot Q_y^i \quad (3.8)$$

Estes índices são calculados para o caso ponderado e não ponderado ($Q_y^i = 1$). Com os índices sem ponderações pode-se ver o seguimento real das variáveis controladas e com os índices ponderados pode-se ver o seguimento fictício que o controle MPC tem de cada variável controlada.

Ao final do período de análise teremos $I_{y_medio}^i$ e $I_{y_medio_p}^i$ ponderados para cada variável controlada.

Para permitir um comparativo entre as variáveis, são calculados os Índices de Seguimento Relativos como mostrado na equação 3.9, onde n é o número de variáveis controladas. Este cálculo relativo dará uma visão percentual dos erros de seguimento de referência das variáveis. Assim os Índices de Seguimento Relativos $I_{y_rel}^i$ e $I_{y_rel_p}^i$ ponderados permitem comparar a influência das ponderações usadas na sintonia do controlador analisando a diferença no valor entre o índice com e sem ponderação para cada variável controlada, como será explicado na seção 3.3.

$$I_{y_rel}^i = \frac{I_{y_medio}^i}{\sum_{j=1}^n I_{y_medio}^j} \quad (3.9)$$

Ambos índices indicam o quanto cada variável controlada representa, em média, de peso na função custo do MPC com relação ao seu erro de seguimento de referência. Portanto quanto menor este índice, melhor será o seguimento da referência desta variável controlada.

3.1.4: Índices Controle Relativo

Estes índices avaliam as variáveis manipuladas do sistema quanto a atividade de sua ação de controle. Baseado na parcela de esforço de controle $\Delta \mathbf{U}^T \mathbf{M}_u^T \mathbf{Q}_u \mathbf{M}_u \Delta \mathbf{U}$ da função custo da equação 3.1. Representado na equação 3.10 e normalizado pela ação de controle em regime permanente (u_{ss}^i) para permitir a comparação com as outras variáveis manipuladas (também deve ser normalizada de forma diferente para

os casos de possível divisão por zero). Estes índices também serão calculados para os casos ponderado e não ponderado ($Q_u^i = 1$) pelo mesmo motivo apresentado para os Índices de Seguimento Relativos.

$$I_{u_{inst}}^i(k) = \left(100 \cdot \frac{\Delta u^i(k)}{u_{ss}^i(k)} \right)^2 \cdot Q_u^i \quad (3.10)$$

Para esses índices também serão aplicadas as fórmulas médias e relativas da mesma forma apresentada para os Índices de Seguimento. E o valor do índice que será analisado é o $I_{u_{medio}}^i$ obtido ao final do período de análise, neste caso também na forma $I_{u_{rel}}^i$ e $I_{u_{rel,p}}^i$ ponderada. O objetivo destes índices é mostrar quais variáveis manipuladas estão sendo mais solicitadas baseado no peso que elas representam na função custo do MPC. Disso conclui-se que quanto maior o índice, maior a variação da variável manipulada.

3.1.5: Índices de Supressão de Movimento

Estes índices avaliam o quanto uma variável controlada está sendo afetada com relação à supressão da variação das variáveis manipuladas imposta pelas ponderações em Q_u que se relacionam a ela. Calculados utilizando a equação 3.11, onde m é o número de variáveis manipuladas e K_{ij} são os ganhos das funções de transferências que são acopladas com aquela variável controlada.

$$I_{sm_{inst}}^i(k) = \frac{[w^i(k)]^2}{\sum_{j=1}^m [\Delta u^j(k) \cdot K_{ij}]^2} \cdot \frac{1}{1000} \quad (3.11)$$

A geração destes índices é feita com o cálculo de média recursiva como nos índices anteriores e o $I_{sm_{medio}}^i$ obtido ao final do período de análise será o valor a ser analisado. Neste caso não será calculado a comparação relativa das variáveis. Quanto maior for este índice, maior será a supressão de movimento que está sendo aplicada as variáveis manipuladas que afetam aquela variável controlada. Como pode ser observado, também nestes índices, a referência da variável controlada é usada como forma de normalizar. Caso a referência seja nula deve ser usado outro valor como, por exemplo, o maior valor esperado da controlada.

3.1.6: Índices do Erro de Modelagem

Estes índices avaliam a qualidade dos modelos de predição usados para prever o comportamento do sistema. Mostrado na equação ??, calcula os erros entre as predições do modelo \tilde{y}^i e as saídas reais do processo y^i normalizados pela referência w^i para permitir a comparação com as outras variáveis controladas.

$$I_{em.inst}^i(k) = 100 \cdot \frac{\|\tilde{y}^i(k) - y^i(k)\|}{w^i(k)} \quad (3.12)$$

Os valores instantâneos são aplicados na equação de média recursiva e o valor do índice que será analisado são os $I_{em.medio}^i$ obtidos ao final do período de análise. O valor destes índices podem ser interpretados como os erros médios de predição de cada variável controlada. Quanto maior for o índice, maior a quantidade de erros nos modelos daquela variável controlada ou necessidade de modelagem de perturbações ainda não modeladas. O mesmo comentário vale aqui, caso a referência seja nula pode ser usado o maior valor esperado da controlada na normalização.

3.2: Apresentação Gráfica dos Resultados

Para facilitar a visualização dos índices foi escolhido o gráfico de barras, por ser intuitivo e permitir comparar o valor final dos índices de cada variável lado a lado. Os Índices de Seguimento Relativos e de Controle Relativos que possuem índices ponderados e não ponderados serão plotados em um mesmo gráfico mas com valores não ponderados no eixo positivo e os valores ponderados no eixo negativo para permitir visualizar a influência que as ponderações estão causando em cada variável analisada.

Quando o sistema apresenta um número muito grande de variáveis manipuladas e controladas e/ou quando não há acoplamento total entre elas, adicionalmente aos gráficos dos índices gerados podem ser utilizados a relação de ganhos das funções de transferência das variáveis para permitir analisar a intensidade que uma possível mudança nas ponderações irá causar na variável em análise e em quais variáveis essa mudança também irá se refletir.

3.3: Método Proposto para Tomada de Decisão

Para ajudar o projetista na análise dos índices, foi criado um método que analisa a situação atual e indica que direção tomar a decisão visando uma mudança de cenário. Antes de iniciar o método é necessário a definição dos objetivos de controle.

Uma vez gerados os índices, a análise tem dois caminhos: Análise dos **índices de avaliação** (desempenho global do sistema) que pode ser feita com os Desvios Médios, junto com os Índices de Estabilidade; e a análise dos **índices de sintonia** (desempenho relativos) feita com os Índices de Seguimento Relativos, Controle Relativos, Supressão de Movimento e Erro de Modelagem.

Para os índices de avaliação deve-se iniciar pelos Desvios Médios para saber se o sistema pode ser melhorado. Para a análise dos índices de sintonia, inicia-se pelos Índices de Seguimento Relativos não ponderados. O objetivo de controle com relação ao seguimento das variáveis deve ser visível nesses índices. Caso esses índices não sejam satisfatórios, é necessário uma análise mais abrangente. O seguimento de referência de uma variável controlada depende: da qualidade do modelo de predição e das ponderações Q_y e Q_u . Para analisar a qualidade dos modelos de predição deve-se olhar o Índice de Erro de Modelagem. Se este índice possuir um valor elevado, então pode-se inferir que o erro do modelo tem grande influência no sistema em malha fechada e seria necessário uma re-identificação do modelo utilizado pelo controlador. Para a análise das ponderações de Q_y deve-se analisar os Índices de Seguimento Relativos e para a análise de Q_u os Índices de Supressão de Movimento.

3.3.1: Análise dos Índices de Seguimento Relativos

Caso a diferença $D = I_{y_{rel}}^i - I_{y_{rel,p}}^i$ seja negativa, a ponderação usada para esta controlada está com grande influência no sistema de controle, de forma que a ponderação pode ser diminuída em benefício de outras controladas com maior importância ou aumentada para se atingir um melhor seguimento.

3.3.2: Análise dos Índices de Supressão de Movimento

Se este índice possui um valor grande, então uma possível causa é a grande supressão das variáveis manipuladas que afetam esta controlada. E caso contrário, então as referidas manipuladas estão com liberdade para agir nesta controlada. Em

ambos os casos para decidir quais ponderações devem ser modificadas, deve-se analisar os Índices de Controle Relativos de cada manipulada. Assim como no caso dos Índices de Seguimento Relativos, se a diferença $D = I_{u,rel}^i - I_{u,rel,p}^i$ for negativa, a ponderação está suprimindo a ação dessa manipulada e pode ser diminuída ou vice-versa. Deve-se analisar somente as variáveis manipuladas que influenciam a dinâmica daquela variável controlada e os ganhos das funções de transferências para se conhecer a intensidade que a mudança deve ser feita.

Capítulo 4: Caso de estudo e ferramentas de simulação e controle

Os índices mostrados no capítulo 3 foram avaliados numa unidade de processamento de gás natural (UPGN) da Petrobrás simulada no software BRLumina, desenvolvido pela própria empresa.

4.1: UPGN

O objetivo do processamento do gás natural é recuperar o propano (C3), o butano (C4) e o pentano e hidrocarbonetos mais pesados (C5+), separando-os dos hidrocarbonetos leves (C1 e C2). O processamento de gás natural gera três produtos finais: o gás industrial (composto por C1 e C2), o GLP (composto por C3 e C4) e a gasolina natural (composta por C5+).

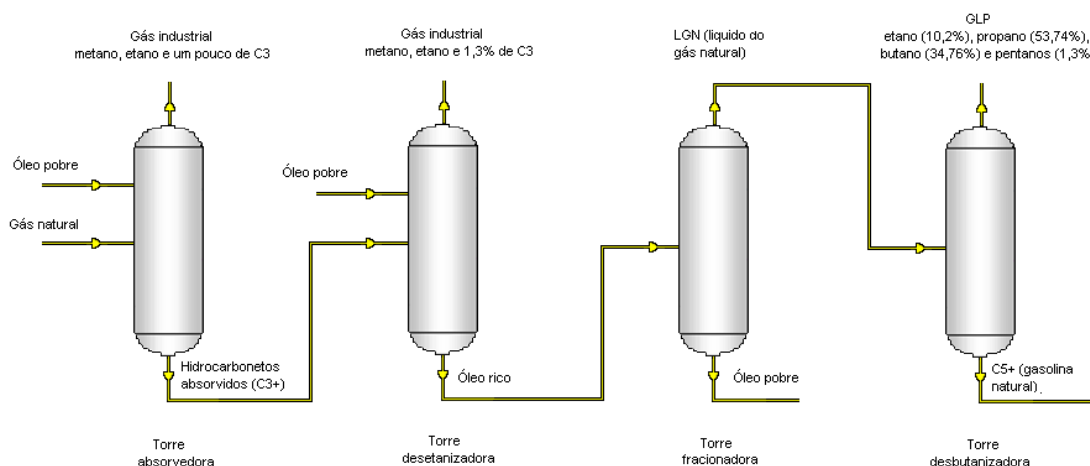


Figura 4.1: Esquema simplificado da UPGN

Nesta unidade, a separação dos hidrocarbonetos é feita através do processo de absorção refrigerada por propano, produzido na própria unidade. Na primeira etapa o gás natural passa pela primeira torre, a torre de absorção, que separa os hidro-

carbonetos mais pesados (absorvidos pelo óleo pobre) dos demais. Pelo topo desta torre sai o gás industrial, composto por metano, etano e C3. E pelo fundo saem os hidrocarbonetos absorvidos. Como este líquido ainda possui metano e etano em sua composição, ele passa pela segunda torre, a desetanizadora, para que estes hidrocarbonetos leves sejam separados. Pelo topo da coluna desetanizadora sai outro gás industrial também composto por metano (C1), etano (C2) e propano (C3), mas em concentrações diferentes do anterior. O C3 presente no gás industrial é uma perda que deve ser minimizada. Pelo fundo da torre desetanizadora sai o óleo rico que é destilado na torre fracionadora gerando LGN (líquido do gás natural) e óleo pobre, que retorna ao início do processo. Depois da torre desetanizadora não resta mais metano na mistura de hidrocarbonetos que continua no sistema. O LGN alimenta o sistema de desbutanização. Na torre desbutanizadora o produto é separado em GLP (gás liquefeito de petróleo), composto por etano (10,2%), propano (53,74%), butano (34,76%) e pentanos (1,3%), e C5+ (gasolina natural). A Figura 4.1 mostra um esquema simplificado do processamento de gás natural com as quatro torres e seus respectivos produtos de topo e de fundo.

Do ponto de vista do controle avançado, esse processo tem 10 entradas, as variáveis manipuladas, e 11 saídas, as variáveis controladas. Além disso, o processo está sujeito a 3 perturbações mensuráveis. As variáveis controladas, manipuladas e perturbações do processo inteiro são mostradas nas tabelas 4.1, 4.2 e 4.3, respectivamente.

Tabela 4.1: Variáveis Controladas

ID	Descrição
y1	Teor de C3 na torre absorvedora (T01)
y2	Teor de C3 na torre absorvedora (T02)
y3	Teor de C2 no GLP
y4	Nível da torre (T02)
y5	Nível da torre (T02)
y6	Vazão de refluxo
y7	Abertura da válvula de pressão da torre T04
y8	Teor de C5 na torre T04
y9	Razão refluxo torre T04
y10	Refluxo mais carga T04
y11	Abertura de válvula

Atualmente as variáveis controladas y5, y9 e y11 não estão sendo utilizadas no problema de controle. A relação entre as variáveis controladas, as manipuladas e as

Tabela 4.2: Variáveis Manipuladas

ID	Descrição
u1	Vazão de óleo de absorção para torre T01
u2	Vazão de óleo de absorção para torre T02
u3	Vazão de carga fria para torre T02
u4	Pressão no topo da T02
u5	Pressão no topo da T04
u6	Temperatura de fundo da T03
u7	Temperatura de topo da T03
u8	Vazão de Refluxo da T04
u9	Controle de Temperatura da T04
u10	Temperatura de fundo da T02

Tabela 4.3: Perturbações

ID	Descrição
w1	Vazão de gás natural (carga) a ser processada pela unidade
w2	Riqueza da carga
w3	Carga na torre T04

perturbações é mostrada na tabela 4.4.

O controle avançado desse processo tem objetivos como maximizar a carga processada na unidade, minimizar a perda de C3 no gás industrial, manter o teor de C2 do GLP dentro da especificação, minimizar a perda de hidrocarbonetos para queima e maximizar o teor de C5+ na gasolina natural. As variáveis mais difíceis de controlar são o teor de C2 no GLP (y_3), abertura da válvula de pressão (y_7) e teor de C5 na gasolina natural (y_7). As seções seguintes explicam brevemente como algumas das variáveis manipuladas e perturbações influenciam no comportamento dessas controladas.

4.1.1: Controle do teor de C2 no GLP - y_3

A concentração de C2 depende principalmente de variáveis relacionadas às torres absorvedora e desetanizadora, que são as torres 01 e 02, respectivamente. O C2 que chega é torre fracionadora, torre 03, sai pelo topo junto com os demais hidrocarbonetos na forma de LGN sem sofrer perdas. Na última torre todo o C2 do LGN também sai pelo topo compondo o GLP. A partir da torre 03 nenhuma variável mensurada é capaz de alterar a concentração final de C2. O objetivo é produzir GLP

Tabela 4.4: Relação entre variáveis controladas manipuladas e perturbações

Variável controlada	Variáveis manipuladas	Perturbações
y1	u1	w1,w2
y2	u1,u2,u3,u10	w1,w2
y3	u1,u2,u10	w1,w2
y4	u6,u7	w1,w2
y5	u1,u3,u4	w1,w2
y6	u6,u7,u10	-
y7	u1,u2,u5,u10	w1,w2
y8	u5,u8,u9	w3
y9	u8,u9	w3
y10	u8	w3
y11	u1,u2,u3,u4,u10	w1,w2

com 15% de C2, mas às vezes restrições operacionais impedem esse teor de ser atingido.

Na torre absorvedora, a variável manipulada que influencia no teor de C2 é a vazão de óleo de absorção (u1). Esta é uma variável importante na absorção dos hidrocarbonetos mais pesados. Ela é manipulada de acordo com a carga processada. Se a carga aumenta, é preciso aumentar a vazão de óleo de absorção para que a quantidade de hidrocarbonetos absorvidos se mantenha.

Na torre desetanizadora, as principais variáveis manipuladas que influenciam no teor de C2 são:

- Vazão da carga fria (u3). Carga fria é a fração da corrente de fundo da torre 01 que vai direto para a torre 02. Sua vazão depende da produção da torre 01. A outra fração da corrente passa por um trocador de calor e também vai pra a torre. A vazão da carga fria é medida, mas a vazão da fração quente não. Ela pode ser estimada através do nível (y4) e da vazão de carga fria.
- Vazão de óleo de absorção (u2). A vazão do óleo de absorção varia de acordo com a vazão de carga fria. Quanto maior a carga, mais óleo de absorção é necessário.
- Temperatura do fundo da torre (u10). Esta temperatura regula a passagem de C2 para a próxima torre. O aumento dessa temperatura aumenta a quantidade de C2 que é retirado do processo e sai pelo topo da coluna, diminuindo a quantidade de C2 que continua no processo.

E as perturbações que influenciam no teor de C2 no GLP são:

- Riqueza do gás natural vindo de outras plataformas. O gás natural processado é uma mistura de gases naturais de várias fontes. Às vezes alguma plataforma para de fornecer e a composição, ou riqueza, da mistura muda. Além disso, a cada 8 horas, a unidade Atalaia também processa um condensado vindo de outra unidade junto com o gás natural. Esse condensado produz um gás muito rico, o que também altera a composição final.
- Vazão de gás natural processada, ou carga processada, também varia de acordo com o fornecimento. Se, por exemplo, uma fonte para de fornecer, além da mudança na riqueza da mistura, há uma diminuição da carga.

Além disso, o teor de C2 pode ser alterado por perturbações não mensuradas. Uma delas é a carga térmica no air cooler (condensador) da desbutanizadora. A planta Atalaia está exposta a variações de temperatura ao longo do dia. Geralmente durante o dia faz muito calor e a noite a temperatura diminui. A chuva também é um fator que influencia na temperatura. Com a temperatura externa mais baixa, a condensação é maior, e por isso é possível conseguir um teor maior de C2 no GLP. Assim, em dias quentes o teor de C2 no GLP produzido normalmente fica abaixo do desejado. Além disso, blocos do air cooler podem ser retirados para manutenção ou limpeza. Isso diminui a superfície de troca de calor, o que resulta em menos gás condensado, e, por consequência, em menor concentração de C2 no GLP.

4.1.2: Controle do teor de C5 na gasolina natural - y8

O teor de C5 na gasolina natural depende das variáveis manipuladas:

- Pressão no topo da torre desbutanizadora (u5), que varia de acordo com a concentração de hidrocarbonetos leves que chegam a essa torre. Quanto maior a concentração de leves, maior a pressão. E quando a pressão aumenta, o teor de C5 diminui.
- Vazão de refluxo da desbutanizadora (u8). Quando a vazão de refluxo de GLP da torre T04 aumenta, a concentração de C5 diminui.
- Controle de temperatura da T04 (u9). Quando a temperatura aumenta, mais hidrocarbonetos leves são incorporados no GLP, aumentando o teor de C5 do produto de fundo.

Além disso, o teor de C5 está sujeito a perturbação de carga na torre T04 (w3). O teor de C5 aumenta à medida que esta carga aumenta.

4.1.3: Controle da abertura da válvula de pressão - y7

Válvula de pressão (y7) na saída da desbutanizadora é uma variável controlada de extrema importância e o seu controle tem preferência em detrimento dos teores, mesmo que isso signifique produzir GLP fora de especificação. Se o controle da válvula de pressão for perdido, a planta pode parar de funcionar. A pressão no topo da torre desbutanizadora varia de acordo com a concentração de hidrocarbonetos leves que chegam a essa torre e causa o fechamento ou abertura da válvula. Quando a pressão está muito alta, a válvula fecha, forçando mais gás em direção ao condensador. Lá esse gás vira líquido e seu volume reduz, diminuindo a pressão. Se a pressão estiver baixa, a válvula abre, deixando mais gás passar direto para o acumulador. A figura 4.2 mostra um esquema simplificado da saída da torre desbutanizadora com a válvula, o acumulador e o condensador.

4.2: BRLumina

O BRLumina é uma ferramenta de simulação de processos controlados pelo CPM. Este software permite a avaliação do funcionamento do controlador em um ambiente offline através da criação de diferentes cenários de operação. Nestes cenários é possível alterar os limites de operação das variáveis, a sintonia do controlador e o ponto de operação. Além disso, os modelos podem ser alterados para introduzir erros de modelagem e perturbações não medidas e é possível introduzir ruídos.

Os cenários a serem simulados no BRLumina devem ser criados dentro de um projeto que contém todos os arquivos necessários para a simulação. Estes arquivos são:

- As DLLs que implementam os algoritmos de controle e de simulação.
- Os arquivos de modelos.
- O arquivo que define as variáveis e perturbações do problema de controle.
- O arquivo que define os parâmetros de sintonia do controle, .

A figura 4.3 mostra a página de criação de um cenário. Nesta etapa são escolhidos os algoritmos de controle e simulação da planta, os modelos de planta e de predição e o tempo de simulação. O BRLumina permite a utilização de dados de perturbações reais na simulação. Isso permite a criação de um cenário mais próximo do real. Uma vez definidos os algoritmos, a planta e o controlador, é hora de escolher os parâmetros de sintonia do controle. Pode-se usar os parâmetros previamente definidos no projeto ou modificá-los.

Os resultados no BRLumina são mostrados em gráficos. O comportamento das variáveis pode ser analisado através de um gráfico simples, que mostra o *target*, o valor de saída e os limites de operação, ou de gráficos multivariáveis, que agrupam várias variáveis para comparação. Diferentes cenários também podem ser comparados através dos gráficos multivariáveis.

Além dos gráficos, uma planilha de resultados .csv é gerada. Nela ficam gravadas os targets, as saídas do processo, os incrementos de controle e outras informações, como *status* e *shadow price*. Apesar do BRLumina gerar um arquivo de resultados bastante completo, o erro de predição não é registrado. Como esta é uma informação necessária para o cálculo do índice de erro de modelagem, uma modificação na DLL de controle foi feita para que arquivos com tais informações fossem gerados.

4.3: Comentários finais

Neste capítulo foram mostradas as ferramentas de simulação e o processo a partir do qual foram criados os cenários de operação, mostrados no capítulo 5, utilizados no estudo dos índices.

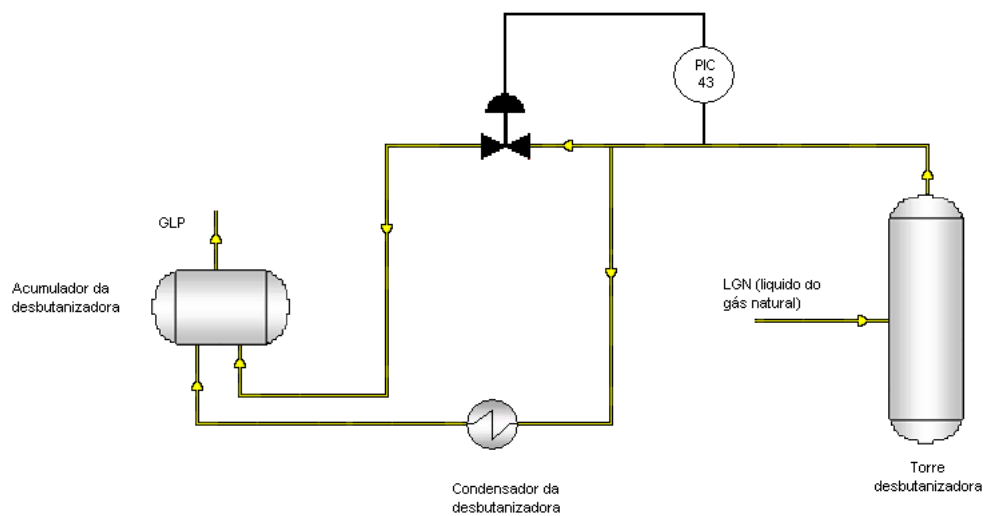


Figura 4.2: Esquema simplificado torre desbutanizadora

Figura 4.3: Exemplo de cenário do BRLumina

Capítulo 5: Implementação do FAST

Este capítulo mostra como o cálculo dos índices foi implementado, que ferramentas foram usadas e que dificuldades foram encontradas para a obtenção dos dados necessários. Como mostrado no capítulo 3, os dados necessários para o cálculo do índices são:

- Referência das variáveis controladas - W
- Valor medido das variáveis controladas - Y
- Predição das variáveis controladas - \bar{Y}
- Ponderação das variáveis controladas - Q_y
- Referência das variáveis manipuladas - u_{ss}
- Incrementos de controle - ΔU
- Ponderação as variáveis manipuladas - Q_u

Os algoritmos que implementam o CPM, tanto na planta real como no BR-Lumina, geram ou recebem automaticamente todos esse dados. No entanto, nem todos ficam armazenados. As predições calculadas para as variáveis controladas eram perdidas de uma iteração para outra do controle. Foram necessárias algumas modificações nesses algoritmos para que a predição fosse salva em arquivos .csv.

Os índices estudados foram calculados a partir dos dados obtidos nas simulações de cenários no BRLumina. A cada passo de simulação, que corresponde a 1 minuto de operação, uma planilha .csv contendo diversos dados gerados pelo CPM é criada num diretório. Uma aplicação desenvolvida em Python varre este diretório e lê cada planilha, copiando apenas os dados necessários para gerar os vetores W , Y , \bar{Y} , Q_y para cada controlada e u_{ss} , Δu e Q_u para cada manipulada.

A partir desses vetores são calculados os índices instantâneos, que por sua vez são usados para calcular os índices médios através da média recursiva mostrada na sessão 3.1. Estes valores finais são plotados em 5 gráficos. São eles:

- Desvio médio total e individual, figura 6.1
- Índice de seguimento relativo, figura 6.2
- Índices de supressão de movimento e controle, figura 6.3
- Índice de erro de modelagem, figura 6.4
- Índice de estabilidade, figura 6.5

Além dos dados provenientes do BRLumina, foram utilizados dados reais medidos na planta e gerados pelo controle da mesma para calcular os índices. Estes dados reais também foram armazenados em planilhas .csv e lidos por uma aplicação em Python que gera os vetores necessários para os cálculos. A partir desses vetores, os cálculos foram feitos da mesma maneira descrita anteriormente.

Para a realização deste trabalho, a implementação do FAST MPC se limita a códigos em Python que lêem as planilhas, geram vetores, calculam os índices e plotam gráficos. Posteriormente, estas rotinas do Python e um algoritmo para auxiliar na tomada de decisão estarão integrados a uma interface que facilitará o uso dos índices.

5.1: Comentários finais

Neste capítulo foram descritas as ferramentas usadas para o cálculo dos índices, assim como o ambiente de simulacao utilizado. No próximo capítulo são analisados os resultados obtidos com estas ferramentas.

Capítulo 6: Avaliação dos índices e resultados

Para avaliar o comportamento dos índices foram criados cenários no BRLumina a partir de arquivos de configuração e modelos utilizados na UPGN. No BRLumina é possível modificar as informações importadas desses arquivos para criar cenários com diferentes sintonias e modelos.

O BRLumina simula não só o controle mas também a camada de otimização na qual são calculados os *targets* para todas as variáveis. Neste processo, as perturbações medidas w_1 e w_2 fazem parte do problema de otimização. Estas perturbações são a vazão e a composição do gás natural na entrada do processo. Então quando seus valores mudam, os *targets* calculados para as variáveis também mudam. Por isso, os valores de perturbação utilizados no cenário zero são valores obtidos a partir de medições reais. Assim, o cenário criado se aproxima muito de uma situação real.

As sessões a seguir explicam os resultados obtidos a partir da análise dos cenários para estudar o funcionamento dos índices.

6.1: Caso zero: cenário inicial

Este cenário, usado como referência, foi criado a partir dos arquivos de configuração do controle e do modelo da UPGN sem que nenhuma modificação fosse feita. Neste caso, chamado cenário zero, o modelo da planta e o de predição são iguais e este modelo é o mesmo usado como modelo de predição no controle da planta real. As matrizes de supressão Q_y e Q_u também não foram alteradas e seus valores são os mesmos utilizados no controle da UPGN.

O gráfico de desvios médios individuais, figura 6.1, mostra que as variáveis controladas y_3 , y_7 e y_8 são as que apresentam maior desvio. O objetivo de controle será então diminuir o desvio das variáveis y_3 , y_7 e y_8 , sem aumentar o desvio das

outras.

Pelo Índice de Estabilidade, figura 6.5, das três variáveis apenas a y_3 possui um espaço que podemos acelerar a dinâmica desta resposta sem levar todo o sistema para a instabilidade. E que a y_7 está em seu limite e não conseguiremos melhorar muito esta resposta.

Pelo Índice de Erro de Modelagem, figura 6.4, vemos que a controlada y_8 está mal modelada. Isto pode ser causado tanto por um modelo de predição ruim quanto pela presença de perturbações não modeladas influenciando nesta resposta. Vemos que a controlada y_1 também tem um modelo ruim mas sua resposta apresenta um baixo desvio médio individual. Corrigir esse modelo não apresenta muita importância, a menos que o objetivo de controle seja manter ela bem controlada.

O Índice de supressão de movimento, figura 6.3, Pelo índice de supressão de movimento vemos que a maior supressão de movimento está na variável y_4 mas essa variável já está fazendo um bom seguimento de referência, provavelmente pela dinâmica rápida da variável. Das variáveis propostas inicialmente para serem melhoradas apenas y_3 tem possibilidade de melhoria modificando as ponderações de Q_u . Para as variáveis y_7 e y_8 deve-se dar mais atenção a ponderação Q_y e aos modelos de predição visto que pelas ponderações de Q_u não será possível nenhuma melhora. As variáveis manipuladas que a influenciam y_3 são: u_1 , u_2 , e u_{10} . Dessas manipuladas, só a u_2 tem uma parcela alta do esforço de controle, como mostra o Índice de Controle na figura 6.3. Neste caso, pelos índices de controle não ponderados, de u_1 e u_{10} estão pouco acionadas e podem ser mais liberadas (diminuindo a ponderação Q_u). A u_2 , apesar de bem manipulada, parece está mais acionada que o real para o controlador, por causa da ponderação. Neste caso, ponderação dela pode ser diminuída para permitir que ela seja mais utilizada.

Estas conclusões foram obtidas seguindo a metodologia de tomada de decisão proposta. No entanto, cenários criados a partir dessas conclusões não mostraram uma melhora no desempenho do sistema, o que sugere que a sintonia já está muito boa para manter o sistema em bom desempenho para os objetivos de controle.

Este cenário zero foi então utilizado como o exemplo de boa sintonia e desempenho deste controle nesta planta. Os dados obtidos nesta simulação foram usados para definir o tamanho da janela de média móvel, mostrada na sessão 3.1, que será usada nos cálculos dos índices nas próximas análises.

A janela móvel usada para calcular os índices médios tem uma grande influ-




Figura 6.1: Desvios Médios




Figura 6.2: Índices de Seguimento Relativo




Figura 6.3: Índices de Supressão de Movimento e Controle Relativo




Figura 6.4: Índices de Erro de Modelagem




Figura 6.5: Índice de Estabilidade

encia no resultado final. Se a janela escolhida for muito pequena, somente amostras muito próximas da atual são consideradas e valores de índices instantâneos muito diferentes poderão levar a conclusões erradas sobre o desempenho do sistema. Se a janela for muito grande, mudanças de sintonia ou ponto de operação, que podem afetar o desempenho do controle, podem demorar muito para aparecer, já que muita informação do passado ainda tem peso no presente. É preciso então escolher uma janela com um tamanho ideal que minimize esses dois efeitos.

Para definir o tempo da janela N_{media} foram calculados os índices com janelas de diferentes tamanhos e o N_{media} que representa o sistema, ou seja, o menor tamanho de janela que gera um resultado que não mudará se a janela for aumentada, foi escolhido.

Assim, foram testados 3 tamanhos de janela: 4, 7 e aproximadamente 15 dias, ou seja, todo o conjunto de dados. Os resultados mudaram muito entre 4 e 7 dias, mas de 7 para 15 não. Por isso, o tamanho escolhido foi 7 dias e todos os cenários mostrados nas próximas sessões tiveram os índices calculados com uma janela de 7 dias.

6.2: Caso 1: cenários com erros de modelagem

Como o objetivo é minimizar o erro entre o target e a predição, um modelo de predição que não representa muito bem o processo pode prejudicar o seguimento

à referência, uma vez que o erro minimizado não corresponde ao erro real, então a diferença entre a referência e a saída pode nunca chegar a zero.

Para verificar o reflexo de erros de modelagem no Índice de Erro Modelagem, foram criados 3 cenários com alterações nos modelos que afetam a variável controlada y_3 . No primeiro cenário, os ganhos estáticos das manipuladas que afetam y_3 foram multiplicados por 1,5. No segundo cenário, o atraso foi aumentado em 40 minutos. No terceiro cenário, os modelos de perturbação para a variável y_3 foram excluídos, na tentativa de simular perturbações não medidas. Estas perturbações, apesar de não representarem as mesmas perturbações não medidas que influenciam no processo real, servem para mostrar como este erro se reflete no índice.



Os três diferentes erros de modelagem inseridos no processo são facilmente notados nos Índices de erro de modelagem. No caso zero, mostrado na figura 6.6a, os valores dos índices de todas as variáveis são baixos e não passam de 0,8, inclusive o da variável y_3 , que é 0,3. Já nos casos com erro de modelagem, os valores dos índices continuam iguais e abaixo de 0,8, mas para a variável y_3 os valores aumentaram consideravelmente. Como mostra a figura 6.6, através dos índices é possível identificar exatamente quais variáveis controladas estão sendo afetadas por erros de modelagem.

Apesar dos erros de modelagem aparecem claramente no índice de erro de modelagem, não é possível identificar a natureza do erro apenas com os índices propostos. Atualmente estão sendo feitos estudos de indicadores que auxiliem na identificação da origem do erro (ganho, atraso, perturbações ou ruídos).

6.3: Caso 2: Cenários com alterações na supressão das ações de controle


Os ajustes das ponderações Q_y e Q_u tem grande influência no desempenho do sistema de controle. A ponderação do esforço de controle Q_u pode ser analisada através dos Índices de Controle Relativos e de Supressão de Movimento, lembrando que o Índice de Supressão de Movimento mostra a visão das controladas e como suas manipuladas estão sendo suprimidas. O Índice de Controle Relativo mostra a visão das manipuladas e o quanto elas estão sendo acionadas em forma percentual ao total.

Como mostra a equação 3.10 do índice de supressão no capítulo 3, página 31,




(a) Caso zero

(b) Erro no ganho



(c) Erro no atraso



(d) Perturbação não medida

Figura 6.6: Índices de Erro de Modelagem


a supressão de uma variável controlada é inversamente proporcional aos incrementos de controle de suas manipuladas. Se o valor de Q_u para uma manipulada for aumentado, os incrementos de controle calculados para essa variável serão menores e sua resposta mais lenta. Assim, o aumento de Q_u de uma manipulada pode aumentar o índice de supressão da variável controlada a qual ela afeta. O contrário acontece quando o valor de Q_u de uma manipulada é reduzido. Como seus incrementos de controle calculados são maiores, o índice de supressão da sua controlada tende a diminuir.

Para verificar esta relação entre as variações de Q_u e o índice de supressão, foram criados dois cenários nos quais as variáveis manipuladas u_1 , u_2 e u_{10} , que são as que afetam a controlada y_3 , destacada em verde, tiveram seus valores de Q_u alterados. No primeiro, cujo resultado é mostrado na figura 6.7b, os valores de Q_u foram aumentados para 50. No segundo, mostrado na figura 6.7c, os valores de Q_u foram reduzidos para 0,5, 0,5 e 0,2 para u_1 , u_2 e u_{10} , respectivamente.


Os valores iniciais de Q_u para essas variáveis manipuladas são 5, 5 e 2 para u_1 , u_2 e u_{10} , respectivamente. A figura 6.7a mostra o caso zero, que usa os valores de Q_u iniciais. A variável y_3 tem um índice de supressão maior no primeiro cenário, figura 6.7b do que no caso zero. Já no segundo caso, o índice de supressão de y_3 é praticamente zero. Houve uma redução em relação ao caso zero. Estes resultados são consistentes com o que se esperava teoricamente. Cenários parecidos foram criados envolvendo outros conjuntos de variáveis controladas e suas manipuladas e todos apresentaram o mesmo comportamento.

6.4: Comentários finais


Os cenários criados para esta etapa do estudo não têm como objetivo validar a tomada de decisão proposta, mas sim mostrar como problemas de modelo e sintonia se refletem nos índices. Além disso, as modificações feitas levaram a um aumento no desvio médio do sistema, o que indica que, apesar de haver erro de seguimento, a atual sintonia do controle está próxima da melhor sintonia possível. É preciso lembrar que os *targets* deste sistema mudam frequentemente, então o regime permanente dificilmente é atingido. Ainda assim, mesmo em casos bastante complexos, onde há um grande acoplamento entre variáveis, os índices fornecem informações consistentes sobre o desempenho e a sintonia do controle.



(a) Caso zero



(b) Q_u de u_1 , u_2 e u_{10} aumentado



(c) Q_u de u_1 , u_2 e u_{10} diminuído

Figura 6.7: Índices de Supressão e Controle Relativo

Capítulo 7: Conclusões e Perspectivas

Os resultados obtidos a partir dos cenários discutidos no capítulo 6 mostram que os índices são capazes de indicar claramente o que está afetando o sistema, mesmo num processo lento, com muitas variáveis de diferentes dinâmicas, com muito atraso e muitas restrições.

Mas apesar dos índices serem capazes de identificar a possível causa de um desempenho ruim, eles não conseguem sozinhos dar detalhes de como corrigir o problema. Por exemplo, um alto valor do índice de erro de modelagem pode ser causado por erros de ganho ou atraso no modelo de predição, ou por perturbações não medidas, ou ainda por ruídos. E essas diferentes causas aparecem nos índices da mesma maneira, elas aumentam o valor do índice de erro de modelagem.

Além disso, somente com os índices de supressão e controle, não é possível determinar o quanto se deve alterar os valores de Q_u para obter uma resposta melhor. Os índices de supressão também são afetados pela velocidade da resposta das variáveis. As mais rápidas se aproximam da referência antes das demais e nessa hora têm incrementos de controle menor, afetando o valor do índice.

Um outro ponto importante e particular da planta estudada é que neste processo os valores de ponderação Q_y dependem do valor das variáveis controladas. Existem 3 valores de Q_y para cada variável: um para quando o valor está acima do limite superior de operação, outro para quando ele está abaixo do limite inferior e um terceiro para quando o valor está dentro dos limites. Isso torna a análise dos Índices de Seguimento Relativos um pouco complicada. E por isso a análise deste índice não foi tão explorada neste trabalho.

Estudos estão sendo feitos para criar indicadores que permitam diferenciar os tipos de erros de modelagem que estão prejudicando o seguimento a referência. Além disso, análises do comportamento dos índices estão sendo feitas para obter um método de solução matemático que defina o quanto se deve modificar as ponderações do controle ajustado.

Referências Bibliográficas

- [1] L. G. Bergh and J. F. MacGregor. Constrained minimum variance controllers: Internal model structure and robustness properties. Ind. Eng. Chem. Res., 26:1558–1564, 1987.
- [2] E.F. Camacho and C. Bordons. Model Predictive Control. Springer, Berlin, 2007.
- [3] D.W. Clarke and C. Mohtadi. Properties of generalized predictive control. Automatica, 25(6):859–875, 1989.
- [4] D.W. Clarke, C. Mohtadi, and P.S. Tuffs. Generalized Predictive Control. Part I: the basic algorithm. Automatica, 23(2):137–148, 1987.
- [5] C.R. Cutler and B. L. Ramaker. Dynamic matrix control-a computer control algorithm. AIChE National Meeting, 1979.
- [6] A. Datta and J. Ochoa. Adaptive Internal Model Control: Design and stability analysis. Automatica, 32(2):261–266, 1996.
- [7] S. Dormido. Una revisión de las tecnologías de control predictivo basado en modelos en la industria. In Wokshop sobre estado y perspectivas del control predictivo, Valladolid, Spain, 1987.
- [8] Rodolfo César Costa Flesch. Contribuições ao Controle de Sistemas Monovariáveis e Multivariáveis com Atraso de Transporte. PhD thesis, Universidade Federal de Santa Catarina, 2012.
- [9] G. Goodwin and K. Sin. Adaptive Filtering Prediction and Control. Prentice Hall, 1984.
- [10] R.M.C. De Keyser and A.R. Cuawenberghe. Extended prediction self adaptive control. In IFAC Simp. on Ident. and Syst. Parameter Estimation, pages 1317–1322, York, 1985.
- [11] H. S. Khalil. Nonlinear Systems. Prentice-Hall, 3rd edition, 2003.
- [12] Manfred Morari, Jay H. Lee, and Carlos E. García. Model Predictive Control. Prentice Hall, 2002.

- [13] D. Miranda Cruz J. E. Normey-Rico P. E. F. Cortez, A. Plucenio. Índices de desempenho para auxílio na re-sintonia de controladores preditivos multivariáveis. Master's thesis, Universidade Federal de Santa Catarina, Dissertação ainda não defendida.
- [14] Z.J. Palmor. Properties of optimal stochastic control systems with dead-time. Automatica, 18:107–116, 1982.
- [15] J.B. Rawlings and D.Q. Mayne. Model Predictive Control: Theory and Design. Nob Hill Publishing, 2009.
- [16] J. Richalet, S. Abu el Ata-Doss, C. Arber, H.B. Kuntze, A. Jacobash, and W. Schill. Predictive functional control. Application to fast and accurate robots. In Proc. 10th IFAC Congress, Munich, 1987.
- [17] J. Richalet, A. Rault, J.L. Testud, and J. Papon. Algorithm control for industrial processes. In Proc. 4th IFAC Symp. on Identification and System Parameter Estimation, Tbilisi, URSS, 1976.
- [18] I. Skrjanc and D. Matko. Advances in Model Based Predictive Control. Chapter: Fuzzy Predictive Controller with Adaptive Gain., chapter 10. Oxford University, 1994.
- [19] R. Soeterboek. Predictive Control: A unified approach. Prentice Hall, 1992.
- [20] Y. Tan and R. De Keyser. Advances in Model Based Predictive Control. Chapter: Neural Network Based Predictive Control., chapter 8. Oxford University, 1994.
- [21] B.E. Ydstie. Extended horizon adaptive control. In 9th IFAC World Congress, Budapest, Hungary, 1984.